

VOL I

Ramon González Calvet  
(Organizador)

PESQUISA  
E DOCENCIA  
EM  
CIENCIAS  
EXATAS  
E NATURAIS



EDITORA  
ARTEMIS  
2026

VOLI

Ramon González Calvet  
(Organizador)

PESQUISA  
E DOCENCIA  
EM  
CIENCIAS  
EXATAS  
E NATURAIS



EDITORA  
ARTEMIS

2026

2026 by Editora Artemis  
Copyright © Editora Artemis  
Copyright do Texto © 2026 Os autores  
Copyright da Edição © 2026 Editora Artemis



O conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons Atribuição-Não-Comercial Não-Derivativos 4.0 Internacional (CC BY-NC-ND 4.0). Direitos para esta edição cedidos à Editora Artemis pelos autores.

Permitido o download da obra e o compartilhamento, desde que sejam atribuídos créditos aos autores, e sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

A responsabilidade pelo conteúdo dos artigos e seus dados, em sua forma, correção e confiabilidade é exclusiva dos autores. A Editora Artemis, em seu compromisso de manter e aperfeiçoar a qualidade e confiabilidade dos trabalhos que publica, **conduz a avaliação cega pelos pares de todos manuscritos publicados, com base em critérios de neutralidade e imparcialidade acadêmica.**

<b>Editora Chefe</b>	Antonella Carvalho de Oliveira
<b>Editora Executiva</b>	M. <sup>a</sup> Viviane Carvalho Mocellin
<b>Direção de Arte</b>	M. <sup>a</sup> Bruna Bejarano
<b>Diagramação</b>	Elisangela Abreu
<b>Organizador</b>	Prof. Dr. Ramon González Calvet
<b>Imagem da Capa</b>	sharuzzaman/123RF
<b>Bibliotecário</b>	Maurício Amormino Júnior – CRB6/2422

#### Conselho Editorial

Prof.<sup>a</sup> Dr.<sup>a</sup> Ada Esther Portero Ricol, *Universidad Tecnológica de La Habana “José Antonio Echeverría”, Cuba*  
Prof. Dr. Adalberto de Paula Paranhos, *Universidade Federal de Uberlândia, Brasil*  
Prof. Dr. Agustín Olmos Cruz, *Universidad Autónoma del Estado de México, México*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Amanda Ramalho de Freitas Brito, *Universidade Federal da Paraíba, Brasil*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Clara Monteverde, *Universidad de Buenos Aires, Argentina*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Júlia Viamonte, *Instituto Superior de Engenharia do Porto (ISEP), Portugal*  
Prof. Dr. Ángel Mujica Sánchez, *Universidad Nacional del Altiplano, Peru*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Angela Ester Mallmann Centenaro, *Universidade do Estado de Mato Grosso, Brasil*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Begoña Blandón González, *Universidad de Sevilla, Espanha*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Carmen Pimentel, *Universidade Federal Rural do Rio de Janeiro, Brasil*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Catarina Castro, *Universidade Nova de Lisboa, Portugal*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Cirila Cervera Delgado, *Universidad de Guanajuato, México*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Cláudia Neves, *Universidade Aberta de Portugal*  
Prof.<sup>a</sup> Dr.<sup>a</sup> Cláudia Padovesi Fonseca, *Universidade de Brasília-DF, Brasil*  
Prof. Dr. Cleberton Correia Santos, *Universidade Federal da Grande Dourados, Brasil*  
Dr. Cristo Ernesto Yáñez León – *New Jersey Institute of Technology, Newark, NJ, Estados Unidos*



Prof. Dr. David García-Martul, *Universidad Rey Juan Carlos de Madrid*, Espanha  
Prof.ª Dr.ª Deuzimar Costa Serra, *Universidade Estadual do Maranhão*, Brasil  
Prof.ª Dr.ª Dina Maria Martins Ferreira, *Universidade Estadual do Ceará*, Brasil  
Prof.ª Dr.ª Edith Luévano-Hipólito, *Universidad Autónoma de Nuevo León*, México  
Prof.ª Dr.ª Eduarda Maria Rocha Teles de Castro Coelho, *Universidade de Trás-os-Montes e Alto Douro*, Portugal  
Prof. Dr. Eduardo Eugênio Spers, *Universidade de São Paulo (USP)*, Brasil  
Prof. Dr. Eloi Martins Senhoras, *Universidade Federal de Roraima*, Brasil  
Prof.ª Dr.ª Elvira Laura Hernández Carballido, *Universidad Autónoma del Estado de Hidalgo*, México  
Prof.ª Dr.ª Emilas Darlene Carmen Lebus, *Universidad Nacional del Nordeste*, Argentina  
Prof.ª Dr.ª Erla Mariela Morales Morgado, *Universidad de Salamanca*, Espanha  
Prof. Dr. Ernesto Cristina, *Universidad de la República*, Uruguay  
Prof. Dr. Ernesto Ramírez-Briones, *Universidad de Guadalajara*, México  
Prof. Dr. Fernando Hitt, *Université du Québec à Montréal*, Canadá  
Prof. Dr. Gabriel Díaz Cobos, *Universitat de Barcelona*, Espanha  
Prof.ª Dr.ª Gabriela Gonçalves, *Instituto Superior de Engenharia do Porto (ISEP)*, Portugal  
Prof.ª Dr.ª Galina Gumovskaya – *Higher School of Economics*, Moscow, Russia  
Prof. Dr. Geoffroy Roger Pointer Malpass, *Universidade Federal do Triângulo Mineiro*, Brasil  
Prof.ª Dr.ª Gladys Esther Leoz, *Universidad Nacional de San Luis*, Argentina  
Prof.ª Dr.ª Glória Beatriz Álvarez, *Universidad de Buenos Aires*, Argentina  
Prof. Dr. Gonçalo Poeta Fernandes, *Instituto Politécnico da Guarda*, Portugal  
Prof. Dr. Gustavo Adolfo Juarez, *Universidad Nacional de Catamarca*, Argentina  
Prof. Dr. Guillermo Julián González-Pérez, *Universidad de Guadalajara*, México  
Prof. Dr. Håkan Karlsson, *University of Gothenburg*, Suécia  
Prof.ª Dr.ª Lara Lúcia Tescarollo Dias, *Universidade São Francisco*, Brasil  
Prof.ª Dr.ª Isabel del Rosario Chiyon Carrasco, *Universidad de Piura*, Peru  
Prof.ª Dr.ª Isabel Yohena, *Universidad de Buenos Aires*, Argentina  
Prof. Dr. Ivan Amaro, *Universidade do Estado do Rio de Janeiro*, Brasil  
Prof. Dr. Iván Ramon Sánchez Soto, *Universidad del Bío-Bío*, Chile  
Prof.ª Dr.ª Ivânia Maria Carneiro Vieira, *Universidade Federal do Amazonas*, Brasil  
Prof. Me. Javier Antonio Albornoz, *University of Miami and Miami Dade College*, Estados Unidos  
Prof. Dr. Jesús Montero Martínez, *Universidad de Castilla - La Mancha*, Espanha  
Prof. Dr. João Manuel Pereira Ramalho Serrano, *Universidade de Évora*, Portugal  
Prof. Dr. Joaquim Júlio Almeida Júnior, *UNIFIMES - Centro Universitário de Mineiros*, Brasil  
Prof. Dr. Jorge Ernesto Bartolucci, *Universidad Nacional Autónoma de México*, México  
Prof. Dr. José Cortez Godinez, *Universidad Autónoma de Baja California*, México  
Prof. Dr. Juan Carlos Cancino Diaz, *Instituto Politécnico Nacional*, México  
Prof. Dr. Juan Carlos Mosquera Feijoo, *Universidad Politécnica de Madrid*, Espanha  
Prof. Dr. Juan Diego Parra Valencia, *Instituto Tecnológico Metropolitano de Medellín*, Colômbia  
Prof. Dr. Juan Manuel Sánchez-Yáñez, *Universidad Michoacana de San Nicolás de Hidalgo*, México  
Prof. Dr. Juan Porras Pulido, *Universidad Nacional Autónoma de México*, México



Prof. Dr. Júlio César Ribeiro, Universidade Federal Rural do Rio de Janeiro, Brasil  
Prof. Dr. Leinig Antonio Perazolli, Universidade Estadual Paulista (UNESP), Brasil  
Prof.ª Dr.ª Livia do Carmo, Universidade Federal de Goiás, Brasil  
Prof.ª Dr.ª Luciane Spanhol Bordignon, Universidade de Passo Fundo, Brasil  
Prof. Dr. Luis Fernando González Beltrán, *Universidad Nacional Autónoma de México*, México  
Prof. Dr. Luis Vicente Amador Muñoz, *Universidad Pablo de Olavide*, Espanha  
Prof.ª Dr.ª Macarena Esteban Ibáñez, *Universidad Pablo de Olavide*, Espanha  
Prof. Dr. Manuel Ramiro Rodriguez, *Universidad Santiago de Compostela*, Espanha  
Prof. Dr. Manuel Simões, Faculdade de Engenharia da Universidade do Porto, Portugal  
Prof.ª Dr.ª Márcia de Souza Luz Freitas, Universidade Federal de Itajubá, Brasil  
Prof. Dr. Marcos Augusto de Lima Nobre, Universidade Estadual Paulista (UNESP), Brasil  
Prof. Dr. Marcos Vinicius Meiado, Universidade Federal de Sergipe, Brasil  
Prof.ª Dr.ª Mar Garrido Román, *Universidad de Granada*, Espanha  
Prof.ª Dr.ª Margarida Márcia Fernandes Lima, Universidade Federal de Ouro Preto, Brasil  
Prof.ª Dr.ª María Alejandra Arecco, *Universidad de Buenos Aires*, Argentina  
Prof.ª Dr.ª Maria Aparecida José de Oliveira, Universidade Federal da Bahia, Brasil  
Prof.ª Dr.ª Maria Carmen Pastor, *Universitat Jaume I*, Espanha  
Prof.ª Dr.ª Maria da Luz Vale Dias – Universidade de Coimbra, Portugal  
Prof.ª Dr.ª Maria do Céu Caetano, Universidade Nova de Lisboa, Portugal  
Prof.ª Dr.ª Maria do Socorro Saraiva Pinheiro, Universidade Federal do Maranhão, Brasil  
Prof.ª Dr.ª M<sup>ª</sup>Graça Pereira, Universidade do Minho, Portugal  
Prof.ª Dr.ª Maria Gracinda Carvalho Teixeira, Universidade Federal Rural do Rio de Janeiro, Brasil  
Prof.ª Dr.ª María Guadalupe Vega-López, *Universidad de Guadalajara*, México  
Prof.ª Dr.ª Maria Lúcia Pato, Instituto Politécnico de Viseu, Portugal  
Prof.ª Dr.ª Maritza González Moreno, *Universidad Tecnológica de La Habana*, Cuba  
Prof.ª Dr.ª Mauriceia Silva de Paula Vieira, Universidade Federal de Lavras, Brasil  
Prof. Dr. Melchor Gómez Pérez, Universidad del Pais Vasco, Espanha  
Prof.ª Dr.ª Ninfa María Rosas-García, Centro de Biotecnología Genómica-Instituto Politécnico Nacional, México  
Prof.ª Dr.ª Odara Horta Boscolo, Universidade Federal Fluminense, Brasil  
Prof. Dr. Osbaldo Turpo-Gebera, *Universidad Nacional de San Agustín de Arequipa*, Peru  
Prof.ª Dr.ª Patrícia Vasconcelos Almeida, Universidade Federal de Lavras, Brasil  
Prof.ª Dr.ª Paula Arcoverde Cavalcanti, Universidade do Estado da Bahia, Brasil  
Prof. Dr. Rodrigo Marques de Almeida Guerra, Universidade Federal do Pará, Brasil  
Prof. Dr. Saulo Cerqueira de Aguiar Soares, Universidade Federal do Piauí, Brasil  
Prof. Dr. Sergio Bitencourt Araújo Barros, Universidade Federal do Piauí, Brasil  
Prof. Dr. Sérgio Luiz do Amaral Moretti, Universidade Federal de Uberlândia, Brasil  
Prof.ª Dr.ª Silvia Inés del Valle Navarro, *Universidad Nacional de Catamarca*, Argentina  
Prof.ª Dr.ª Solange Kazumi Sakata, Instituto de Pesquisas Energéticas e Nucleares (IPEN)- USP, Brasil  
Prof.ª Dr.ª Stanislava Kashtanova, *Saint Petersburg State University*, Russia  
Prof.ª Dr.ª Susana Álvarez Otero – Universidad de Oviedo, Espanha

Prof.ª Dr.ª Teresa Cardoso, Universidade Aberta de Portugal

Prof.ª Dr.ª Teresa Monteiro Seixas, Universidade do Porto, Portugal

Prof. Dr. Valter Machado da Fonseca, Universidade Federal de Viçosa, Brasil

Prof.ª Dr.ª Vanessa Bordin Viera, Universidade Federal de Campina Grande, Brasil

Prof.ª Dr.ª Vera Lúcia Vasilévski dos Santos Araújo, Universidade Tecnológica Federal do Paraná, Brasil

Prof. Dr. Wilson Noé Garcés Aguilar, *Corporación Universitaria Autónoma del Cauca*, Colômbia

Prof. Dr. Xosé Somoza Medina, *Universidad de León*, Espanha

**Dados Internacionais de Catalogação na Publicação (CIP)  
(eDOC BRASIL, Belo Horizonte/MG)**

P475 Pesquisa e docência em ciências exatas e naturais [livro eletrônico] / Organizador Ramon González Calvet. – 1. ed. – Curitiba, PR: Editora Artemis, 2026.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Edição bilíngue

Inclui bibliografia.

ISBN 978-65-82858-10-9

DOI 10.37572/EdArt\_270626109

1. Ciências exatas. 2. Ciências naturais. 3. Pesquisa científica. 4. Docência. I. González Calvet, Ramon.

CDD 500

**Elaborado por Maurício Amormino Júnior – CRB6/2422**



## PRÓLOGO

La producción del conocimiento científico y educativo en el campo de las ciencias exactas y naturales se caracteriza, cada vez más, por su capacidad de articular fundamentos teóricos, desarrollos tecnológicos, prácticas formativas y compromisos sociales. En este contexto, el primer volumen de ***Pesquisa e Docência em Ciências Exatas e Naturais*** reúne un conjunto plural de trabajos que evidencian la vitalidad de la investigación contemporánea y la importancia de repensar la docencia como espacio de construcción, mediación y circulación del saber.

Los capítulos que integran esta obra permiten percibir la amplitud de un campo que no se limita a la transmisión de contenidos de disciplinas científicas, sino que se abre a problemas complejos, metodologías diversas y experiencias docentes. La investigación matemática, físico-química y computacional convive aquí con la ingeniería aplicada, la inteligencia artificial, la ética profesional, la educación matemática, la enseñanza de las ciencias, la formación superior y la preservación del conocimiento paleontológico. Esta diversidad temática refleja una visión amplia de las ciencias exactas y naturales, entendidas no solo como áreas de formulación abstracta y experimentación técnica, sino también como prácticas humanas, educativas e institucionales.

El volumen se inicia con trabajos dedicados a la modelización matemática, físico-química y al estudio de sistemas complejos. En este primer conjunto, se abordan problemas relacionados con operadores diferenciales, semigrupos de contracciones, isothermas de adsorción, gases reales, potenciales de Lennard-Jones y Morse, nanoestructuras y configuraciones de mínimo potencial. Estos capítulos destacan la importancia de la modelización, la abstracción y la simulación en la comprensión de fenómenos naturales y materiales.

En un segundo momento, la obra se orienta hacia las tecnologías aplicadas, la ingeniería y los medios digitales en la formación científica. Los trabajos reunidos en esta parte muestran cómo el desarrollo tecnológico puede contribuir tanto a la creación de dispositivos y soluciones aplicadas como a la transformación de los procesos formativos. La presencia de estudios sobre electroestimulación, generación de gráficos vectoriales mediante reconocimiento de voz, aprendizaje profundo e inteligencia artificial en contextos universitarios evidencia la necesidad de repensar la innovación técnica junto con sus implicaciones educativas, epistemológicas y profesionales.

La tercera parte concentra investigaciones orientadas a la docencia, el aprendizaje y la equidad en contextos educativos diversos. Los capítulos analizan cuestiones vinculadas a la ética en ingeniería, a la inclusión en educación matemática,

al liderazgo y desempeño docente, a las actitudes hacia la estadística, al aprendizaje basado en proyectos, a la relación entre sueño y aprendizaje, y a la calidad educativa en la formación superior en odontología. En conjunto, estos trabajos subrayan que enseñar ciencias y matemáticas exige mucho más que dominio de la disciplina: requiere sensibilidad pedagógica, reflexión institucional, innovación metodológica y atención a las condiciones reales de aprendizaje de los estudiantes.

Finalmente, el volumen se cierra con una contribución singular dedicada a las ciencias naturales, los acervos fósiles y la preservación del conocimiento paleontológico. A partir de una trayectoria de décadas en la prospección, colección y exhibición de fósiles, este capítulo invita a reflexionar sobre la colaboración entre iniciativas privadas, museos, universidades e instituciones científicas. Su presencia al final de la obra ofrece un cierre significativo, al recordar que la ciencia también depende de la conservación, documentación y accesibilidad de los materiales que permiten reconstruir la historia natural.

De este modo, ***Pesquisa e Docência em Ciências Exatas e Naturais*** propone una lectura que avanza desde los fundamentos científicos y matemáticos hacia las aplicaciones tecnológicas, los medios digitales, los desafíos de la enseñanza y la preservación del patrimonio natural. La obra evidencia que investigar y enseñar están profundamente interrelacionadas: toda investigación produce nuevas preguntas para la formación, y toda práctica docente comprometida puede convertirse en espacio de investigación, innovación y transformación. De hecho, solo se puede enseñar bien a los estudiantes aquel conocimiento que los investigadores antes comprendieron bien.

Esperamos que este volumen contribuya al diálogo entre investigadores, docentes, estudiantes y profesionales interesados en las ciencias exactas y naturales, fortaleciendo una perspectiva integradora, crítica y colaborativa del conocimiento. Que los trabajos aquí reunidos sirvan como punto de partida para nuevas investigaciones, nuevas prácticas pedagógicas y nuevas formas de aproximarse a los desafíos científicos y educativos de nuestro tiempo.

**Ramon González Calvet**

## SUMARIO

### MODELACIÓN MATEMÁTICA, FÍSICO-QUÍMICA Y ESTRUCTURAS EN SISTEMAS COMPLEJOS

#### **CAPÍTULO 1.....1**

CONTRAST WITH THE HILLE-YOSIDA'S THEOREM AND THE CONTRACTION SEMIGROUP FOR AN ODD-ORDER DIFFERENTIAL OPERATOR

Yolanda Silvia Santiago Ayala

 [https://doi.org/10.37572/EdArt\\_2706261091](https://doi.org/10.37572/EdArt_2706261091)

#### **CAPÍTULO 2.....17**

ISOTERMA DE ADSORCIÓN DEDUCIDA DEL MODELO DEL BILLAR Y ECUACIÓN DE ESTADO APLICADA A LOS GASES REALES

Ramon González Calvet

 [https://doi.org/10.37572/EdArt\\_2706261092](https://doi.org/10.37572/EdArt_2706261092)

#### **CAPÍTULO 3.....32**

VERDADERAS NANOESTRUCTURAS DE MÍNIMO POTENCIAL GLOBAL DE LENNARD JONES Y MORSE

Carlos Barrón Romero

 [https://doi.org/10.37572/EdArt\\_2706261093](https://doi.org/10.37572/EdArt_2706261093)

#### **CAPÍTULO 4..... 48**

NUEVAS PEQUEÑAS NANOESTRUCTURAS DE MÍNIMO POTENCIAL DE LENNARD JONES Y MORSE

Carlos Barrón Romero

 [https://doi.org/10.37572/EdArt\\_2706261094](https://doi.org/10.37572/EdArt_2706261094)

### TECNOLOGÍAS APLICADAS, INGENIERÍA Y MEDIOS DIGITALES EN LA FORMACIÓN CIENTÍFICA

#### **CAPÍTULO 5..... 66**

DISEÑO Y GENERACIÓN DE UN ELECTROESTIMULADOR TENS CON DIFERENTES TIPOS DE PULSOS

Eduardo García Sánchez

Luis Eduardo Bañuelos García

Mario Molina Almaraz  
Osbaldo Vite Chávez  
José Manuel Cervantes Viramontes  
María del Rosario Martínez Blanco  
Luis Octavio Solís Sánchez  
Irerí Aydee Sustaita Torres  
Pilar Cecilia Godina González  
Francisco Javier Martínez Ruíz  
Sahara Araceli Pereyra López  
Ana Lourdes Aracely Borrego Elías

 [https://doi.org/10.37572/EdArt\\_2706261095](https://doi.org/10.37572/EdArt_2706261095)

**CAPÍTULO 6..... 84**

GRÁFICOS VECTORIALES SVG GENERADOS A PARTIR DE INSTRUCCIONES POR VOZ MEDIANTE LA LIBRERÍA *SPEECH RECOGNITION*

Moisés García Villanueva  
Salvador Ramírez Zavala

 [https://doi.org/10.37572/EdArt\\_2706261096](https://doi.org/10.37572/EdArt_2706261096)

**CAPÍTULO 7 ..... 99**

DE LAS REDES NEURONALES RECURRENTES A LOS TRANSFORMADORES: EVOLUCIÓN Y ANÁLISIS CRÍTICO DE LOS PARADIGMAS FUNDAMENTALES DEL APRENDIZAJE PROFUNDO

Adolfo Melendez Ramirez  
Francisco Jacob Avila Camacho  
Juan Manuel Stein Carrillo  
Leonardo Miguel Moreno Villalba

 [https://doi.org/10.37572/EdArt\\_2706261097](https://doi.org/10.37572/EdArt_2706261097)

**CAPÍTULO 8..... 116**

DISRUPCIÓN ALGORÍTMICA Y CONFIGURACIÓN DEL SABER INVESTIGATIVO: LA INTELIGENCIA ARTIFICIAL COMO DISPOSITIVO EPISTEMOLÓGICO EN ESTUDIANTES UNIVERSITARIOS DE ICA, PERÚ

José Ángel Meneses Jiménez  
Pedro Julián Ormeño Carmona  
Manuel Rocha Gonzales  
Beny Pasquel Flores  
Jorge Luis Arrué Flores

 [https://doi.org/10.37572/EdArt\\_2706261098](https://doi.org/10.37572/EdArt_2706261098)

## DOCENCIA, APRENDIZAJE Y EQUIDAD EN MATEMÁTICAS, CIENCIAS Y FORMACIÓN SUPERIOR

### **CAPÍTULO 9.....129**

INCLUSIÓN Y EQUIDAD EN EDUCACIÓN MATEMÁTICA: PERSPECTIVAS TEÓRICAS Y DEBATES ACTUALES

Carmen Cecilia Espinoza Melo

Erich Leighton Vallejos

 [https://doi.org/10.37572/EdArt\\_2706261099](https://doi.org/10.37572/EdArt_2706261099)

### **CAPÍTULO 10.....138**

PERCEPCIÓN ESTUDIANTIL SOBRE EL LIDERAZGO Y DESEMPEÑO DOCENTE DE PROFESORES DE MATEMÁTICAS Y SU RELACIÓN CON LOS RESULTADOS DE APRENDIZAJE

Francisco Javier Saavedra Álvarez

Raúl Arnaldo Fuentes Fuentes

Paola Ramírez González

 [https://doi.org/10.37572/EdArt\\_27062610910](https://doi.org/10.37572/EdArt_27062610910)

### **CAPÍTULO 11.....165**

ELIMINANDO ACTITUDES NEGATIVAS HACIA LA ESTADÍSTICA EN PSICOLOGÍA: EFECTOS DEL APRENDIZAJE DEL ANÁLISIS DE TEXTOS

Luis Fernando González Beltrán

Olga Rivas García

 [https://doi.org/10.37572/EdArt\\_27062610911](https://doi.org/10.37572/EdArt_27062610911)

### **CAPÍTULO 12.....175**

¿QUÉ FUNCIONA (Y QUÉ NO) PARA INCORPORAR LA ÉTICA COMO COMPETENCIA TRANSVERSAL EN ESTUDIOS DE INGENIERÍA?

Ester Gimenez-Carbo

Lourdes Soriano Martínez

 [https://doi.org/10.37572/EdArt\\_27062610912](https://doi.org/10.37572/EdArt_27062610912)

### **CAPÍTULO 13.....183**

DEL AULA AL ENTORNO: EL APRENDIZAJE BASADO EN PROYECTOS COMO ESTRATEGIA PARA LA ENSEÑANZA DE LA QUÍMICA AMBIENTAL

Elizabeth Gonzalez Sepúlveda

Victor Neira

Felipe Neira

 [https://doi.org/10.37572/EdArt\\_27062610913](https://doi.org/10.37572/EdArt_27062610913)

**CAPÍTULO 14..... 194**

CORRELACIÓN ENTRE EL SUEÑO Y EL APRENDIZAJE EN ESTUDIANTES DE MEDICINA: UNA REVISIÓN SISTEMÁTICA

Juan Camilo González Torres

Orlando Miguel González Torres

Irina Tirado Ballestas

 [https://doi.org/10.37572/EdArt\\_27062610914](https://doi.org/10.37572/EdArt_27062610914)

**CAPÍTULO 15.....206**

HABLANDO DE CALIDAD EDUCATIVA EN LA FORMACIÓN SUPERIOR EN ODONTOLOGÍA: DESAFÍOS EN LA DOCENCIA DE LAS CIENCIAS DE LA SALUD

Martha Patricia de la Rosa-Basurto

Jesús Rivas-Gutiérrez

Nelly Alejandra Rodríguez Guajardo

Christian Starlight Franco-Trejo

Luz Patricia Falcón-Reyes

Alejandra Estefania Esquivel-Lozano

Zitzingore Janitzi López-Aguilar

 [https://doi.org/10.37572/EdArt\\_27062610915](https://doi.org/10.37572/EdArt_27062610915)

**CIENCIAS NATURALES, ACERVOS Y PRESERVACIÓN DEL CONOCIMIENTO PALEONTOLÓGICO**

**CAPÍTULO 16.....220**

40 YEARS AS A FOSSIL PROSPECTOR, COLLECTOR, AND EXHIBITION MAKER

H.J. "Kirby" Siber

 [https://doi.org/10.37572/EdArt\\_27062610916](https://doi.org/10.37572/EdArt_27062610916)

**ACERCA DEL ORGANIZADOR.....231**

**ÍNDICE ALFABÉTICO..... 232**

# CAPÍTULO 7

## DE LAS REDES NEURONALES RECURRENTES A LOS TRANSFORMADORES: EVOLUCIÓN Y ANÁLISIS CRÍTICO DE LOS PARADIGMAS FUNDAMENTALES DEL APRENDIZAJE PROFUNDO

Data de submissão: 06/06/2026

Data de aceite: 19/06/2026

### **Adolfo Melendez Ramirez**

Tecnológico Nacional de México  
Tecnológico de Estudios  
Superiores de Ecatepec  
Ecatepec de Morelos, Méx., México  
<https://orcid.org/0000-0002-4751-0089>

### **Francisco Jacob Avila Camacho**

Tecnológico Nacional de México  
Tecnológico de Estudios  
Superiores de Ecatepec  
Ecatepec de Morelos, Méx., México  
<https://orcid.org/0000-0002-0086-5827>

### **Juan Manuel Stein Carrillo**

Tecnológico Nacional de México  
Tecnológico de Estudios  
Superiores de Ecatepec  
Ecatepec de Morelos, Méx., México  
<https://orcid.org/0000-0003-3594-504X>

### **Leonardo Miguel Moreno Villalba**

Tecnológico Nacional de México  
Tecnológico de Estudios  
Superiores de Ecatepec  
Ecatepec de Morelos, Méx., México  
<https://orcid.org/0000-0003-0937-3586>

**RESUMEN:** El aprendizaje profundo (Deep Learning) ha experimentado una evolución significativa durante las últimas décadas, convirtiéndose en uno de los pilares fundamentales de la Inteligencia Artificial moderna. Desde la introducción de las Redes Neuronales Recurrentes (RNN), diseñadas para el procesamiento de secuencias temporales, hasta el desarrollo de las Redes Neuronales Convolucionales (CNN), que revolucionaron la visión por computadora, y la aparición de los Transformadores, que transformaron el procesamiento del lenguaje natural y dieron origen a los actuales modelos fundacionales, cada paradigma ha contribuido de manera decisiva al avance de los sistemas inteligentes (Hochreiter & Schmidhuber, 1997; LeCun et al., 1998; Vaswani et al., 2017). Este capítulo presenta una revisión analítica y crítica de estas tres arquitecturas fundamentales, examinando sus principios de funcionamiento, capacidades computacionales, aplicaciones predominantes y limitaciones inherentes. Se analizan aspectos relacionados con la representación del conocimiento, la capacidad para modelar dependencias complejas, la eficiencia computacional, la escalabilidad y la adaptabilidad a diferentes dominios de aplicación, incluyendo el procesamiento del lenguaje natural, la visión artificial, la robótica y los sistemas inteligentes basados en datos. Asimismo, se discute el impacto que los Transformadores han tenido en el surgimiento de los Foundation Models y la Inteligencia

Artificial Generativa, destacando su papel en el desarrollo de sistemas multimodales capaces de integrar texto, imágenes, audio y video dentro de una misma arquitectura (Devlin et al., 2019; Brown et al., 2020; Bommasani et al., 2021). A partir de este análisis, se identifican desafíos abiertos relacionados con la interpretabilidad, el consumo energético, la dependencia de grandes volúmenes de datos y las limitaciones en el razonamiento causal. Finalmente, se argumenta que la evolución del aprendizaje profundo no debe interpretarse como una sustitución lineal de paradigmas, sino como un proceso de complementariedad tecnológica en el que RNN, CNN y Transformadores continúan coexistiendo y aportando soluciones especializadas a problemas específicos. El capítulo concluye identificando las principales tendencias emergentes que probablemente orientarán el desarrollo de la Inteligencia Artificial durante la próxima década, incluyendo arquitecturas híbridas, modelos multimodales, IA Generativa, IA Agéntica y enfoques orientados a la sostenibilidad computacional.

**PALABRAS CLAVE:** aprendizaje profundo; Redes Neuronales Recurrentes; Redes Neuronales Convolucionales; Transformadores; Foundation Models; Inteligencia Artificial Generativa; Modelos Multimodales; Análisis Comparativo.

## FROM RECURRENT NEURAL NETWORKS TO TRANSFORMERS: EVOLUTION AND CRITICAL ANALYSIS OF THE FUNDAMENTAL PARADIGMS OF DEEP LEARNING

**ABSTRACT:** Deep Learning has undergone significant evolution over the last decades, becoming one of the fundamental pillars of modern Artificial Intelligence. From the introduction of Recurrent Neural Networks (RNNs), designed for processing temporal sequences, to the development of Convolutional Neural Networks (CNNs), which revolutionized computer vision, and the emergence of Transformers, which transformed natural language processing and gave rise to current foundation models, each paradigm has contributed decisively to the advancement of intelligent systems (Hochreiter & Schmidhuber, 1997; LeCun et al., 1998; Vaswani et al., 2017). This chapter presents an analytical and critical review of these three fundamental architectures, examining their operating principles, computational capabilities, predominant applications, and inherent limitations. It analyzes aspects related to knowledge representation, the ability to model complex dependencies, computational efficiency, scalability, and adaptability to different domains of application, including natural language processing, artificial vision, robotics, and data-driven intelligent systems. Likewise, the chapter discusses the impact that Transformers have had on the emergence of Foundation Models and Generative Artificial Intelligence, highlighting their role in the development of multimodal systems capable of integrating text, images, audio, and video within a single architecture (Devlin et al., 2019; Brown et al., 2020; Bommasani et al., 2021). Based on this analysis, open challenges are identified, including interpretability, energy consumption, dependence on large volumes of data, and limitations in causal reasoning. Finally, it is argued that the evolution of deep learning should not be understood as a linear replacement of paradigms, but rather as a process of technological complementarity in which RNNs, CNNs, and Transformers continue to coexist and provide specialized solutions to specific problems. The chapter concludes by identifying the main emerging trends that will likely guide the development of Artificial Intelligence over the next decade, including

hybrid architectures, multimodal models, Generative AI, Agentic AI, and approaches oriented toward computational sustainability.

**KEYWORDS:** Deep Learning; Recurrent Neural Networks; Convolutional Neural Networks; Transformers; Foundation Models; Generative Artificial Intelligence; Multimodal Models; Comparative Analysis.

## 1. INTRODUCCIÓN

La Inteligencia Artificial (IA) se ha consolidado como una de las tecnologías más influyentes del siglo XXI, impactando sectores tan diversos como la salud, la educación, la manufactura, las telecomunicaciones y la investigación científica. Dentro de este contexto, el aprendizaje profundo (Deep Learning) ha desempeñado un papel central al permitir que los sistemas computacionales aprendan representaciones complejas directamente a partir de grandes volúmenes de datos, superando muchas de las limitaciones asociadas con los enfoques tradicionales de aprendizaje automático (Goodfellow et al., 2016).

La evolución de las arquitecturas neuronales ha seguido una trayectoria caracterizada por la búsqueda de modelos capaces de representar relaciones cada vez más complejas entre los datos y el conocimiento. Las Redes Neuronales Recurrentes (RNN) constituyeron uno de los primeros avances significativos en el procesamiento de secuencias, permitiendo modelar dependencias temporales en tareas relacionadas con lenguaje natural, reconocimiento de voz y análisis de series temporales (Hochreiter & Schmidhuber, 1997). Posteriormente, las Redes Neuronales Convolucionales (CNN) revolucionaron la visión por computadora al demostrar una capacidad sobresaliente para extraer características jerárquicas de imágenes y video (LeCun et al., 1998; Krizhevsky et al., 2012).

Un cambio de paradigma ocurrió con la introducción de los Transformadores, cuya arquitectura basada en mecanismos de atención eliminó la dependencia de estructuras recurrentes y permitió entrenar modelos de gran escala con niveles de desempeño sin precedentes (Vaswani et al., 2017). Esta innovación dio origen a los denominados Foundation Models, incluyendo arquitecturas como BERT, GPT, Gemini, Claude y Llama, que actualmente constituyen la base tecnológica de gran parte de los sistemas de IA generativa contemporáneos (Devlin et al., 2019; Brown et al., 2020; Touvron et al., 2023).

Sin embargo, el éxito de los modelos fundacionales ha puesto de manifiesto nuevas limitaciones relacionadas con la interpretabilidad, el razonamiento causal, la

dependencia de grandes cantidades de datos, el elevado consumo energético y la dificultad para incorporar mecanismos robustos de aprendizaje continuo (Schwartz et al., 2020; Bommasani et al., 2021). Estas restricciones han impulsado el surgimiento de nuevas líneas de investigación centradas en la integración de capacidades cognitivas avanzadas, incluyendo memoria persistente, razonamiento simbólico, planificación autónoma y adaptación dinámica al contexto.

En este escenario emergen la IA Agéntica, los sistemas neuro-simbólicos y las propuestas de arquitecturas cognitivas adaptativas como posibles candidatos para la próxima generación de sistemas inteligentes (Bengio, 2024). Entre estas propuestas destaca el concepto de Arquitecturas Neuronales Adaptativas (ANA), entendido como un marco conceptual orientado a la convergencia de múltiples paradigmas de aprendizaje, razonamiento y autonomía dentro de una infraestructura flexible y escalable.

Por ello, el objetivo de este capítulo es analizar críticamente la evolución de las principales arquitecturas del aprendizaje profundo, desde las RNN hasta los modelos fundacionales contemporáneos, identificando sus fortalezas, limitaciones y tendencias futuras.

**Contexto histórico:** La evolución de la inteligencia artificial (IA) y el aprendizaje automático (ML) ha estado marcada por hitos significativos, donde cada época ha impulsado nuevos modelos y arquitecturas que transformaron el campo. En sus inicios, las redes neuronales artificiales (ANN) sentaron las bases de las técnicas modernas de aprendizaje profundo. Sin embargo, la introducción de las Redes Neuronales Recurrentes (RNN) en la década de 1980 por Rumelhart et al. (1986) representó un punto de inflexión, al permitir el procesamiento de datos secuenciales y tareas dependientes del tiempo. Las RNN abrieron la puerta a aplicaciones como el reconocimiento de voz y el modelado del lenguaje, donde el orden de las entradas es crítico.

Con la creciente demanda de reconocimiento de patrones más sofisticados, surgieron las Redes Neuronales Convolucionales (CNN) en los años 90, destacándose el trabajo de LeCun et al. (1998). Las CNN revolucionaron el procesamiento de imágenes gracias a capas convolucionales que extraían características de forma automática y jerárquica. Este avance mejoró drásticamente la precisión en tareas como clasificación de imágenes y detección de objetos, consolidando a las CNN como un pilar en la visión por computadora.

El cambio de paradigma más reciente llegó con la arquitectura Transformer de Vaswani et al. (2017). A diferencia de las RNN, los Transformers emplearon un mecanismo de autoatención, procesando secuencias completas de datos en paralelo y superando

las limitaciones de las RNN en dependencias de largo alcance. Desde entonces, los Transformers se han erigido como la base de modelos de vanguardia en procesamiento del lenguaje natural (NLP), como BERT (Devlin et al., 2018) y GPT (Brown et al., 2020), extendiéndose incluso a dominios como visión artificial y tareas multimodales.

**Objetivo del capítulo:** El objetivo de este capítulo es examinar críticamente la evolución de las arquitecturas neuronales que han marcado el desarrollo del aprendizaje profundo, identificando los cambios paradigmáticos que condujeron desde los modelos recurrentes y convolucionales hasta los actuales modelos fundacionales basados en atención.

## 2. FUNDAMENTO TEORICO

### 2.1. REDES NEURONALES RECURRENTES (RNN)

**Funcionamiento básico de las RNN:** Las Redes Neuronales Recurrentes (RNN) son una clase de redes neuronales que destacan en el procesamiento de datos secuenciales al mantener un estado oculto que captura información de pasos de tiempo anteriores. Esta conexión recurrente permite que la red propague información de un paso al siguiente, lo que le facilita modelar dependencias temporales.

La arquitectura de las RNN puede describirse formalmente de la siguiente manera: dada una secuencia de entrada  $x = (x_1, x_2, \dots, x_T)$ , el estado oculto  $h_t$  en el paso de tiempo  $t$  se calcula como:

$$h_t = \sigma(W_{hh} h_{t-1} + W_{xh} x_t)$$

Donde  $W_{hh}$  y  $W_{xh}$  son matrices de pesos, y  $\sigma$  es una función de activación (Elman, 1990).

**Aplicaciones clave:** Las RNN se han aplicado ampliamente en diversas tareas secuenciales, particularmente en Procesamiento del Lenguaje Natural (NLP) y predicción de series de tiempo. Han demostrado eficacia en tareas como modelado de lenguaje (Mikolov et al., 2010), reconocimiento de voz (Graves et al., 2013) y traducción automática (Sutskever et al., 2014). En el modelado de lenguaje, las RNN predicen la siguiente palabra en una secuencia basándose en el contexto proporcionado por las palabras anteriores, aprovechando su capacidad para mantener información a lo largo de los pasos de tiempo.

**Limitaciones:** A pesar de sus fortalezas, las RNN enfrentan desafíos significativos, particularmente el problema del gradiente que se desvanece, que obstaculiza su capacidad para aprender dependencias a largo plazo (Bengio et al., 1994). A medida que los gradientes se retropropagan a través del tiempo, pueden

disminuir exponencialmente, dificultando que la red aprenda de información pasada distante. Esta limitación ha llevado al desarrollo de arquitecturas más avanzadas, como las Redes de Memoria a Largo Corto Plazo (LSTM) (Hochreiter & Schmidhuber, 1997) y las Unidades Recurrentes con Puertas (GRU) (Cho et al., 2014), las cuales mitigan este problema al incorporar mecanismos para gestionar mejor el flujo de información a lo largo de los pasos de tiempo.

## 2.2. REDES NEURONALES CONVOLUCIONALES (CNN)

**Estructura y funcionamiento de las CNN:** Las Redes Neuronales Convolucionales (CNN) están diseñadas para procesar datos estructurados en forma de cuadrícula, como imágenes, aplicando filtros convolucionales que extraen características jerárquicas. Una CNN típicamente consta de capas convolucionales, capas de pooling y capas totalmente conectadas. La capa convolucional aplica un conjunto de filtros entrenables que se deslizan sobre la imagen de entrada, generando mapas de características que capturan jerarquías espaciales en los datos.

Este proceso puede expresarse matemáticamente como:

$$F_{ij}^k = (W^k * X)_{ij} + b^k,$$

Donde  $F_{ij}^k$  es el mapa de características en la posición  $(i,j)$  para el filtro  $k$ -ésimo,  $W^k$  es el peso del filtro y  $b^k$  es el término de sesgo (LeCun et al., 1998).

**Aplicaciones clave:** Las CNN se han convertido en el estándar de facto para tareas de visión por computadora gracias a su capacidad para capturar características espaciales con alta precisión. Se han aplicado exitosamente en clasificación de imágenes (Krizhevsky et al., 2012), detección de objetos (Girshick et al., 2014) y segmentación de imágenes (Long et al., 2015). Por ejemplo, en tareas de clasificación de imágenes, las CNN aprenden automáticamente a detectar bordes, texturas y patrones complejos, que luego se utilizan para clasificar imágenes en categorías.

**Limitaciones:** Aunque las CNN son potentes, presentan desventajas, como su dependencia de grandes conjuntos de datos etiquetados para entrenamiento y su alto costo computacional. Entrenar CNN profundas suele requerir recursos computacionales significativos (como GPU) y grandes volúmenes de datos etiquetados para evitar el sobreajuste (Goodfellow et al., 2016). Además, las CNN no están diseñadas para capturar dependencias temporales, lo que limita su aplicabilidad en tareas que requieren procesamiento de datos secuenciales, como el análisis de video.

## 2.3. TRANSFORMERS

Arquitectura y mecanismo de atención: Los Transformers, introducidos por Vaswani et al. (2017), representan un cambio de paradigma en el diseño de redes neuronales, especialmente para tareas de secuencia a secuencia. A diferencia de las RNN, que procesan datos secuencialmente, los Transformers utilizan un mecanismo de autoatención que les permite procesar secuencias completas de manera simultánea. Este mecanismo calcula una suma ponderada de la secuencia de entrada, donde los pesos se determinan por la relevancia de cada parte de la secuencia respecto a un token específico.

Esto se expresa matemáticamente como:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V,$$

donde  $Q$ ,  $K$  y  $V$  son las matrices de consulta, clave y valor, y  $d_k$  es la dimensión de los vectores clave (Vaswani et al., 2017).

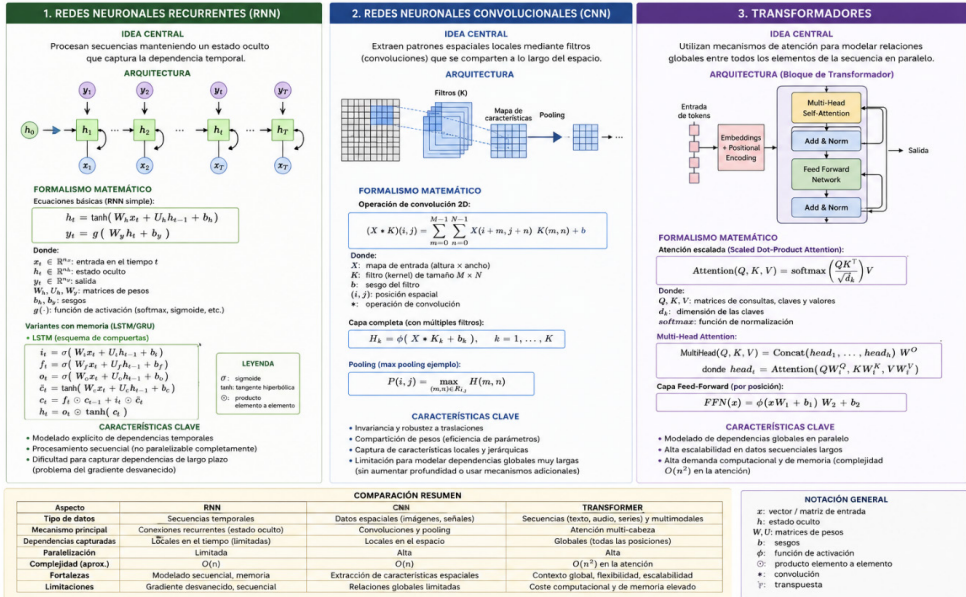
**Aplicaciones clave:** Los Transformers se han convertido en la base de modelos de vanguardia en NLP, como BERT (Devlin et al., 2018), GPT (Brown et al., 2020) y T5 (Raffel et al., 2020). Estos modelos han logrado rendimientos sin precedentes en tareas como traducción de lenguaje, resumen de texto y respuesta a preguntas. La capacidad de los Transformers para capturar dependencias de largo alcance y procesar datos en paralelo también ha impulsado su aplicación en áreas más allá del NLP, como visión por computadora (Dosovitskiy et al., 2021) y predicción de estructuras de proteínas (Jumper et al., 2021).

**Impacto y eficiencia:** La eficiencia y escalabilidad de los Transformers los han posicionado como la opción preferida para aplicaciones a gran escala. A diferencia de las RNN, los Transformers pueden entrenarse de manera más eficiente gracias a la paralelización, lo que reduce significativamente el tiempo de entrenamiento (Vaswani et al., 2017). Además, su modularidad permite adaptarlos y ajustarlos fácilmente para diferentes tareas y dominios, haciéndolos altamente versátiles en el campo del aprendizaje automático.

En la figura 1. Presentamos un resumen grafico del formalismo de cada paradigma, ANN, CNN y trasformadores.

## FORMALISMO DE LOS PARADIGMAS FUNDAMENTALES DEL APRENDIZAJE PROFUNDO

Resumen matemático, arquitectónico y funcional de RNN, CNN y Transformadores



## 3. ANALISIS COMPARATIVO

### 3.1. RENDIMIENTO

El rendimiento de las Redes Neuronales Recurrentes (RNN), las Redes Neuronales Convolucionales (CNN) y los Transformers varía significativamente según la tarea específica, reflejando sus arquitecturas y filosofías de diseño subyacentes.

**Rendimiento de las RNN:** Las RNN son especialmente efectivas en tareas que involucran datos secuenciales, como pronósticos de series de tiempo, modelado de lenguaje y traducción automática. Su capacidad para mantener un estado oculto que captura información de entradas previas las hace ideales para tareas donde el contexto temporal es crucial (Elman, 1990). Sin embargo, las RNN estándar tienen dificultades con dependencias de largo alcance debido al problema del gradiente que se desvanece, lo que limita su rendimiento en tareas que requieren retener información en secuencias extensas (Bengio et al., 1994). La introducción de las redes de Memoria a Largo Plazo (LSTM) (Hochreiter & Schmidhuber, 1997) y las Unidades Recurrentes con Puertas (GRU) (Cho et al., 2014) mitigó estos problemas, mejorando su capacidad para manejar secuencias largas.

**Rendimiento de las CNN:** Las CNN se han convertido en el referente estándar para tareas relacionadas con imágenes, gracias a su capacidad de extraer características jerárquicas. En clasificación de imágenes, por ejemplo, han demostrado un rendimiento de vanguardia, logrando alta precisión al aprender automáticamente bordes, texturas y patrones complejos (Krizhevsky et al., 2012). También han mostrado resultados sobresalientes en detección de objetos y segmentación (Girshick et al., 2014; Long et al., 2015). No obstante, las CNN son menos efectivas para procesar secuencias temporales, lo que restringe su uso en dominios como análisis de video o procesamiento de lenguaje natural.

**Rendimiento de los Transformers:** Los Transformers han superado a las RNN y CNN en muchas tareas de secuencia a secuencia, especialmente en procesamiento del lenguaje natural (NLP). El mecanismo de autoatención de los Transformers les permite analizar secuencias completas de una vez, capturando dependencias de largo alcance mejor que las RNN (Vaswani et al., 2017). Esto ha impulsado avances en traducción automática, resumen de texto y respuesta a preguntas, con modelos como BERT (Devlin et al., 2018) y GPT (Brown et al., 2020) estableciendo nuevos récords en NLP. Además, se han adaptado a visión artificial, donde modelos como Vision Transformers (ViT) igualan el rendimiento de las CNN en clasificación de imágenes (Dosovitskiy et al., 2021).

### 3.2. ESCALABILIDAD Y EFICIENCIA COMPUTACIONAL

La escalabilidad y la eficiencia computacional son factores críticos al comparar RNN, CNN y Transformers, especialmente en modelos de gran escala aplicados a conjuntos de datos complejos.

**Escalabilidad y eficiencia de las RNN:** Las RNN son menos escalables que las CNN y los Transformers debido a su naturaleza secuencial. La necesidad de procesar entradas de manera dependiente del tiempo limita la paralelización durante el entrenamiento, lo que genera tiempos de entrenamiento más largos y costos computacionales elevados, especialmente para secuencias largas (Pascanu et al., 2013). Arquitecturas como LSTM y GRU, aunque más eficientes que las RNN estándar, siguen enfrentando desafíos de escalabilidad por su diseño inherente.

**Escalabilidad y eficiencia de las CNN:** Las CNN, aunque demandan muchos recursos debido a las operaciones de convolución, se benefician de un alto grado de paralelismo. El uso de GPUs ha mejorado significativamente su eficiencia, permitiéndoles manejar grandes conjuntos de datos de imágenes (Krizhevsky et al., 2012). Sin embargo, la profundidad de las CNN puede aumentar los costos computacionales,

especialmente en redes muy profundas como ResNet (He et al., 2016), que requieren más recursos para entrenamiento e inferencia.

**Escalabilidad y eficiencia de los Transformers:** Los Transformers son altamente escalables y eficientes, especialmente en procesamiento paralelo. El mecanismo de autoatención les permite procesar secuencias en paralelo, reduciendo drásticamente los tiempos de entrenamiento frente a las RNN (Vaswani et al., 2017). No obstante, la complejidad cuadrática de la autoatención (respecto a la longitud de la secuencia) plantea desafíos para secuencias muy largas, lo que ha impulsado investigaciones para optimizar su eficiencia, como mecanismos de atención dispersa (Child et al., 2019) y otras modificaciones para reducir costos computacionales (Katharopoulos et al., 2020).

**Transformers Scalability and Efficiency:** Transformers are highly scalable and efficient, especially in parallel processing. The self-attention mechanism allows Transformers to process sequences in parallel, significantly reducing training times compared to RNNs (Vaswani et al., 2017). However, the quadratic time complexity of self-attention with respect to sequence length presents challenges for very long sequences, leading to ongoing research in optimizing Transformers for efficiency, such as through sparse attention mechanisms (Child et al., 2019) and other modifications to reduce computational costs (Katharopoulos et al., 2020).

### 3.3. FLEXIBILIDAD Y APLICACIONES

La flexibilidad de estos modelos es clave al elegir la arquitectura adecuada para una aplicación específica.

**Flexibilidad y aplicaciones de las RNN:** Las RNN son altamente flexibles en aplicaciones con secuencias temporales, como reconocimiento de voz, modelado de lenguaje y traducción automática (Graves et al., 2013; Sutskever et al., 2014). Aunque su capacidad para modelar secuencias las hace adaptables, sus limitaciones con dependencias de largo alcance han llevado al desarrollo de arquitecturas especializadas como LSTM y GRU para manejar secuencias más largas.

**Flexibilidad y aplicaciones de las CNN:** Las CNN se usan principalmente en visión por computadora, pero también se han adaptado a análisis de video y, con modificaciones, a clasificación de texto (Kim, 2014). Su arquitectura, enfocada en jerarquías espaciales, las hace menos flexibles en tareas no visuales, a menos que se combinen con otras arquitecturas (ej: híbridos CNN-LSTM) para datos temporales.

**Flexibilidad y aplicaciones de los Transformers:** Los Transformers son altamente versátiles y se han aplicado en NLP, visión artificial (Dosovitskiy et al., 2021),

aplicaciones multimodales (Lu et al., 2019) e incluso aprendizaje por refuerzo (Chen et al., 2021). Su capacidad para procesar datos secuenciales y no secuenciales, junto con su escalabilidad, los convierte en la arquitectura más flexible de las tres, adaptándose a un amplio espectro de tareas.

Cada arquitectura de redes neuronales – RNN, CNN y Transformers – tiene sus propios desafíos y limitaciones, que influyen en su efectividad según la tarea.

En la siguiente tabla no. 1 mostramos un resumen cualitativo de sus principales características:

Tabla 1. La tabla muestra una comparación de las principales características de cada uno de los paradigmas analizados.

<b>Métrica</b>	<b>RNN</b>	<b>CNN</b>	<b>Transformadores</b>
<b>Tipo de datos predominante</b>	Secuencias temporales	Datos espaciales e imágenes	Secuencias y datos multimodales
<b>Mecanismo principal</b>	Reurrencia y estado oculto	Convoluciones y pooling	Autoatención (Self-Attention)
<b>Capacidad para dependencias de largo alcance</b>	Baja a media (LSTM/GRU mejoran el desempeño)	Limitada	Muy alta
<b>Extracción de características locales</b>	Limitada	Excelente	Buena
<b>Procesamiento paralelo</b>	Bajo	Alto	Muy alto
<b>Escalabilidad</b>	Baja	Alta	Muy alta
<b>Costo computacional de entrenamiento</b>	Medio	Alto	Muy alto
<b>Consumo de memoria</b>	Moderado	Moderado	Elevado
<b>Dependencia de grandes volúmenes de datos</b>	Media	Alta	Muy alta
<b>Capacidad de generalización</b>	Buena en tareas secuenciales	Muy buena en visión artificial	Excelente en dominios diversos
<b>Interpretabilidad</b>	Baja	Media	Media
<b>Robustez frente a secuencias largas</b>	Limitada	No aplicable	Excelente
<b>Flexibilidad de aplicación</b>	Media	Media-Alta	Muy alta
<b>Madurez tecnológica</b>	Alta	Muy alta	Muy alta
<b>Aplicaciones representativas</b>	Series de tiempo, NLP clásico, voz	Clasificación de imágenes, detección de objetos, segmentación	NLP, IA generativa, multimodalidad, visión artificial
<b>Principal limitación</b>	Gradiente desvanecido y falta de paralelización	Dependencia de datos etiquetados y relaciones globales limitadas	Alto costo computacional y energético

## 4. RESULTADOS DEL ANALISIS CRITICO

### RNN: Desafíos y Limitaciones

- **Gradientes que se desvanecen o explotan:** Las RNN son especialmente susceptibles a este problema durante la retropropagación a través del tiempo (BPTT). Esto ocurre porque los gradientes pueden reducirse o crecer exponencialmente al propagarse en el tiempo, dificultando el aprendizaje de dependencias a largo plazo. Por ello, las RNN suelen tener problemas en tareas que requieren retener información en secuencias largas (Bengio, Simard y Frasconi, 1994). Aunque arquitecturas como LSTM y GRU abordaron este problema, el desafío persiste en redes muy profundas o secuencias extensas (Hochreiter y Schmidhuber, 1997).
- **Limitación del procesamiento secuencial:** Las RNN procesan datos de forma secuencial (una entrada a la vez), lo que limita su eficiencia durante el entrenamiento al no aprovechar el procesamiento en paralelo. Esto genera tiempos de entrenamiento más prolongados y menor escalabilidad frente a arquitecturas como CNN y Transformers (Pascanu, Mikolov y Bengio, 2013).

### CNN: Desafíos y Limitaciones

- **Dependencias de datos:** Las CNN requieren grandes volúmenes de datos etiquetados para alcanzar alto rendimiento, especialmente en clasificación de imágenes o detección de objetos. Esto dificulta su aplicación en dominios con datos escasos o costosos de etiquetar (Krizhevsky, Sutskever y Hinton, 2012). Además, pueden sufrir sobreajuste si no se regularizan adecuadamente, sobre todo con datos limitados o poco diversos.
- **Manejo limitado de secuencias:** Aunque las CNN capturan jerarquías espaciales, no están diseñadas para procesar datos secuenciales. Esto las hace menos aptas para tareas temporales (ej: modelado de lenguaje o reconocimiento de voz) sin modificaciones significativas o modelos híbridos (como CNN-LSTM) (Gehring et al., 2017).

### Transformers: Desafíos y Limitaciones

- **Complejidad computacional:** Los Transformers, aunque potentes, implican costos computacionales elevados, especialmente con secuencias largas. El mecanismo de autoatención (central en su arquitectura) escala cuadráticamente con la longitud de la secuencia, lo que lo hace

computacionalmente costoso para secuencias muy extensas (Vaswani et al., 2017). Esto ha impulsado el desarrollo de variantes más eficientes, como Reformer y Longformer, que buscan reducir la carga computacional de la atención (Kitaev, Kaiser y Levskaya, 2020; Beltagy, Peters y Cohan, 2020).

- **Dependencia de grandes volúmenes de datos:** Al igual que las CNN, los Transformers requieren datos masivos para desempeñarse bien, especialmente en modelado de lenguaje. Su fase de preentrenamiento (ej: BERT y GPT) implica entrenar con corpus enormes, consumiendo recursos y tiempo (Devlin et al., 2018; Brown et al., 2020). Además, el ajuste fino para tareas específicas también demanda recursos considerables.

En la tabla no. 2 se realiza un concentrado de los resultados obtenidos del análisis comparativo.

Tabla 2. Resultados destacables de RNN, CNN y Transformadores.

Arquitectura	Modelo representativo	Año	Tarea	Resultado destacado
RNN	LSTM	1997	Modelado de secuencias	Reducción significativa del problema del gradiente desvanecido
RNN	GRU	2014	Traducción automática	Desempeño comparable a LSTM con menor complejidad computacional
CNN	LeNet-5	1998	Reconocimiento de dígitos	Error <1% en MNIST
CNN	AlexNet	2012	ImageNet	Error Top-5 de 15.3%, reduciendo significativamente el estado del arte
CNN	ResNet-152	2015	ImageNet	Error Top-5 cercano al 3.6%
Transformer	Transformer Base	2017	Traducción EN-DE	Mejora BLEU frente a arquitecturas recurrentes
Transformer	BERT	2019	NLP	Estado del arte en múltiples benchmarks GLUE
Transformer	GPT-3	2020	Generación de lenguaje	175 mil millones de parámetros
Transformer	Vision Transformer (ViT)	2021	Clasificación de imágenes	Rendimiento comparable o superior a CNN profundas
Transformer	GPT-4	2023	Multimodal	Desempeño competitivo en múltiples exámenes profesionales y académicos

## 5. TRABAJOS FUTUROS

La evolución de RNN, CNN y Transformers continúa, con investigaciones centradas en superar sus limitaciones y ampliar su aplicabilidad.

### **RNN: Direcciones futuras**

- **Mejorar el aprendizaje de dependencias a largo plazo:** Futuras investigaciones podrían enfocarse en arquitecturas o técnicas de entrenamiento que mitiguen el problema del gradiente evanescente mejor que las soluciones actuales (Bengio et al., 1994). Enfoques como las redes neuronales aumentadas con memoria (MANN) y las máquinas de Turing neuronales son prometedores, permitiendo almacenar y recuperar información en horizontes temporales más largos (Graves et al., 2014).
- **Incorporar mecanismos de atención:** Integrar atención en RNN (como en los Transformers) podría ayudarles a enfocarse en partes relevantes de la secuencia, mejorando su capacidad para manejar secuencias largas y dependencias complejas (Bahdanau, Cho y Bengio, 2015). Este enfoque híbrido podría combinar las fortalezas de RNN y arquitecturas basadas en atención.

### **CNN: Direcciones futuras**

- **Ampliación más allá de la visión:** Aunque las CNN se usan principalmente en visión por computadora, existe un interés creciente en adaptarlas a otros dominios, como el procesamiento de lenguaje natural y la genómica. Los avances en convoluciones unidimensionales y la combinación de CNN con RNN o Transformers podrían mejorar su aplicabilidad a datos secuenciales (Bai, Kolter y Koltun, 2018). Explorar estas aplicaciones cruzadas podría descubrir nuevas capacidades y ampliar los casos de uso de las CNN.
- **Reducción de requisitos de datos:** Abordar la dependencia de datos es un área crítica para futuras investigaciones en CNN. Técnicas como el aprendizaje por transferencia, el aprendizaje semi-supervisado y el aumento de datos se están explorando para reducir la cantidad de datos etiquetados necesarios para entrenar CNN sin comprometer su rendimiento (Zoph et al., 2020). Además, el desarrollo de métodos de aprendizaje con pocos ejemplos (few-shot learning) podría permitir que las CNN generalicen mejor con muestras limitadas, haciéndolas más prácticas en entornos con escasez de datos.

### **Transformers: Direcciones futuras**

- **Modelos Transformer eficientes:** Dados los desafíos computacionales de los Transformers, futuras investigaciones se enfocarán en variantes más eficientes que manejen secuencias largas con menor costo computacional. Modelos como el Reformer (Kitaev et al., 2020) y el Longformer (Beltagy et al., 2020)

representan esfuerzos iniciales en esta dirección, pero se necesitan más innovaciones para hacerlos más escalables y accesibles para diversas tareas.

- **Ampliación de capacidades multimodales:** Los Transformers han mostrado potencial en tareas multimodales que integran datos de fuentes como texto, imágenes y audio (Lu et al., 2019). Futuros estudios podrían explorar modelos más sofisticados que procesen múltiples modalidades de manera fluida, creando sistemas de IA más robustos capaces de entender y generar contenido multimodal complejo. Además, el desarrollo de modelos unificados que realicen diversas tareas en distintas modalidades con mínimo ajuste fino es un área prometedora.

## 6. CONCLUSIONES

En el campo en constante evolución del aprendizaje automático, las Redes Neuronales Recurrentes (RNN), las Redes Neuronales Convolucionales (CNN) y los Transformers aportan fortalezas y limitaciones únicas a diversas aplicaciones. Tras revisar su desarrollo y rendimiento, destacan las siguientes conclusiones:

1. **Fortalezas específicas para tareas distintas:** Cada arquitectura está especializada en tipos de tareas particulares. Las RNN sobresalen en tareas que involucran datos secuenciales, como análisis de series de tiempo y modelado de lenguaje, gracias a su capacidad para mantener un estado oculto que captura dependencias temporales. Por otro lado, las CNN son altamente efectivas en tareas relacionadas con datos espaciales, como clasificación de imágenes y detección de objetos, debido a su capacidad de extracción jerárquica de características. Los Transformers han demostrado un rendimiento superior en el manejo de dependencias de largo alcance y secuencias complejas, especialmente en tareas de procesamiento del lenguaje natural. Su versatilidad también ha permitido adaptaciones para aplicaciones en visión y multimodalidad.
2. **Desafíos que afectan el rendimiento:** A pesar de sus fortalezas, cada arquitectura enfrenta desafíos significativos. Las RNN tienen dificultades con dependencias a largo plazo debido a los gradientes que se desvanecen o explotan, y su naturaleza de procesamiento secuencial limita su escalabilidad y eficiencia en el entrenamiento. Las CNN requieren grandes cantidades de datos etiquetados y son menos adecuadas para datos secuenciales a menos que se combinen con otras arquitecturas. Los Transformers,

aunque potentes, enfrentan altos costos computacionales y demandas de datos, especialmente al manejar secuencias largas. Estos desafíos resaltan la necesidad de investigación continua para mejorar el rendimiento y aplicabilidad de cada arquitectura.

- 3. Direcciones futuras e innovaciones:** El futuro de estas arquitecturas radica en abordar sus limitaciones y expandir sus capacidades. Para las RNN, investigaciones sobre la mejora del aprendizaje de dependencias a largo plazo y la integración de mecanismos de atención son prometedoras. Las CNN podrían beneficiarse de innovaciones que reduzcan los requisitos de datos y amplíen su uso más allá de tareas relacionadas con imágenes. Es probable que los Transformers vean avances continuos en eficiencia, con nuevas variantes diseñadas para manejar secuencias largas y datos multimodales de manera más efectiva. El desarrollo de modelos híbridos y arquitecturas novedosas desempeñará un papel crucial para superar las limitaciones actuales y desbloquear nuevas aplicaciones.
- 4. Impacto global en el aprendizaje automático:** Los avances en RNN, CNN y Transformers han tenido un impacto profundo en el campo del aprendizaje automático, impulsando el progreso en aplicaciones como visión por computadora, procesamiento del lenguaje natural y aprendizaje multimodal. Comprender las fortalezas y limitaciones de estas arquitecturas permite a los profesionales elegir el modelo más adecuado para sus necesidades específicas y ampliar los límites de lo posible con las tecnologías de aprendizaje automático.

## BIBLIOGRAFIA

1. Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166.
2. Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.
3. Chen, M., Tworek, J., Jun, H., Yuan, Q., de Oliveira Pinto, H. P., Kaplan, J., ... & Zaremba, W. (2021). Decision transformer: Reinforcement learning via sequence modeling. *arXiv preprint arXiv:2106.01345*.
4. Child, R., Gray, S., Radford, A., & Sutskever, I. (2019). Generating long sequences with sparse transformers. *arXiv preprint arXiv:1904.10509*.
5. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.

6. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
7. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
8. Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179-211.
9. Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 580-587.
10. Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, 6645-6649.
11. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
12. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
13. Katharopoulos, A., Vyas, A., Pappas, N., & Fleuret, F. (2020). Transformers are RNNs: Fast autoregressive transformers with linear attention. *Proceedings of the 37th International Conference on Machine Learning*, 119, 5156-5165.
14. Kim, Y. (2014). Convolutional neural networks for sentence classification. *arXiv preprint arXiv:1408.5882*.
15. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
16. Lu, J., Batra, D., Parikh, D., & Lee, S. (2019). Vilbert: Pretraining task-agnostic visiolinguistic representations for vision-and-language tasks. *Advances in Neural Information Processing Systems*, 32, 13-23.
17. Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. *International Conference on Machine Learning*, 1310-1318.
18. Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. *Advances in Neural Information Processing Systems*, 27, 3104-3112.
19. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gómez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998-6008.

## ACERCA DEL ORGANIZADOR



**Ramon González Calvet** (1964) es licenciado (1986) y doctor en Química Fundamental por la Universitat de Barcelona (1993). También obtuvo el máster en Matemáticas para profesores por la Universitat Autònoma de Barcelona (1995). Ganó las oposiciones a profesor de matemáticas de secundaria (1987) y fue catedrático de secundaria (2008). Actualmente está jubilado. Ha enseñado álgebra geométrica (de Clifford) a profesores en diversas escuelas de verano, de donde surgió el *Treatise of Plane Geometry through Geometric Algebra* (2007). Durante muchos años hasta el confinamiento, también formó a graduados y

profesores interinos que querían ganar las oposiciones a profesor de matemáticas de secundaria. Sus investigaciones se centran principalmente en interfaces electrificadas, álgebra geométrica, el problema de los  $n$  cuerpos, la geometría diferencial, la mecánica celeste y los relojes de sol. Su aterrizaje en el problema de los  $n$  cuerpos fue accidental. En su etapa de estudiante en la facultad de química, se dio cuenta de que el hamiltoniano electrónico del átomo de helio no podía ser deducido de ninguna manera lógica, puesto que el problema de los tres cuerpos no tenía solución general conocida. En consecuencia, se planteó y resolvió cómo expresar la energía cinética en términos de las velocidades relativas, lo que le permitió obtener las ecuaciones del movimiento clásico de los tres y  $n$  cuerpos en términos de coordenadas y aceleraciones relativas. Después, también dedujo los hamiltonianos de los correspondientes problemas cuánticos, que era su objetivo inicial. Aplicó su hamiltoniano de los tres cuerpos al estudio de los niveles de energía vibracional del dióxido de carbono, y de la energía electrónica del átomo de helio, corrigiendo los hamiltonianos dados previamente por otros autores. Después de describir analíticamente el movimiento del sistema Sol-Tierra-Luna en una serie de tres artículos, y de estudiar la dinámica y evolución del sistema solar en una serie de cinco artículos resumidos en el primer capítulo del libro *Planets, Moons, and Beyond: Unveiling the Mysteries of the Solar System* (2026), sus últimos artículos tratan sobre el billar como modelo de la adsorción de moléculas sobre una superficie, y sobre la forma de los glóbulos rojos. Su tesis doctoral sobre termodinámica de interfases electrificadas todavía permanece inédita, aunque su contenido fue parcialmente explicado en algunos artículos.

## ÍNDICE ALFABÉTICO

### A

Análisis Comparativo 100, 111, 157

Aprendizaje 84, 85, 86, 97, 99, 100, 101, 102, 103, 105, 109, 110, 112, 113, 114, 117, 118, 126, 127, 129, 130, 131, 132, 133, 134, 135, 136, 138, 139, 140, 141, 142, 143, 144, 145, 149, 153, 156, 158, 159, 160, 161, 163, 164, 165, 166, 167, 168, 172, 173, 177, 178, 180, 183, 184, 185, 186, 187, 190, 191, 192, 193, 194, 195, 198, 202, 203, 205, 206, 208, 209, 212, 215, 216, 217, 219

Aprendizaje Basado en Proyectos 178, 183, 184, 185, 186, 187, 188, 190, 192, 193

Aprendizaje profundo 99, 100, 101, 102, 103

### C

Calidad educativa 159, 206, 207, 208, 209, 213, 214, 215, 216, 217, 218, 219

Ciencias de la salud 206, 207

Coeficientes del virial 17, 23, 24, 27

Competencias 116, 118, 119, 121, 124, 128, 134, 136, 166, 176, 177, 178, 181, 183, 184, 185, 186, 187, 190, 191, 192, 206, 209, 210, 211, 212, 218

Competencias digitales 116

Competencia transversal 175, 177, 182

Contraction semigroups 1

Correlación estadística 116, 119, 121

### D

Desempeño docente percibido 138, 144, 146, 149, 155, 157, 158, 160, 161

Didáctica de la matemática 129, 134

Dinámica molecular 32, 48

Dissipative operators 1

Diversidad 129, 130, 131, 132, 134, 135, 136, 143, 162

Docencia universitaria 174, 207

DUA 129, 134

### E

Educación ambiental 184, 185, 186

Educación matemática inclusiva 129, 131, 132, 134, 135, 136

Educación superior 116, 117, 165, 175, 176, 183, 184, 185, 186, 191, 192, 206, 207, 210, 211, 213, 214, 215, 217, 218, 219

Electro-estimulador 67, 69, 70, 71, 72, 74, 76, 80  
Electroterapia 67, 69, 72, 76, 77, 78, 79, 82, 83  
Equidade educativa 129, 131  
Estatística 17, 116, 119, 121, 151, 154, 165, 166, 167, 168, 169, 170, 172, 171, 173, 174  
Estudantes 116, 117, 119, 121, 122, 123, 125, 126, 127, 128, 130, 131, 132, 133, 134, 135, 138, 139, 140, 141, 142, 143, 144, 145, 146, 148, 149, 150, 151, 152, 154, 155, 156, 157, 158, 159, 160, 161, 164, 166, 167, 168, 171, 173, 174, 175, 181, 183, 185, 186, 187, 188, 189, 190, 191, 192, 194, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205, 206, 208, 209, 210, 211, 212, 215, 216, 217, 218  
Estudantes de medicina 194, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205  
Estudios de ingeniería 175, 181  
Ética 127, 142, 175, 176, 177, 178, 179, 180, 181, 182

## F

Formação profissional 186, 207  
Fossil collecting 220  
Foundation Models 99, 100, 101  
Fourier analysis 1, 16

## G

Gas de esferas blandas 17, 28  
Gas de esferas duras 17, 23, 25, 26, 30  
Gráficos Vectoriais 84, 86, 87, 88, 89, 90, 95  
Green River Formation 220, 221, 222

## H

Habilidades investigativas 116, 119, 121, 122, 123, 124, 127  
Hille-Yosida theorem 1

## I

Inteligencia artificial 99, 100, 101, 102, 116, 117, 118, 119, 122, 124, 125, 127  
Inteligência Artificial Generativa 99, 100  
Interacción Humano Máquina 84  
Isoterma del billar 17

## J

Justicia social 129, 131, 133, 134, 135, 136

## L

Liderazgo 138, 139, 140, 141, 142, 143, 144, 146, 147, 149, 150, 151, 154, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 177, 183, 185, 186, 188, 189, 190, 191, 192

## M

Matemáticas 16, 44, 74, 90, 91, 129, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 141, 142, 143, 144, 145, 149, 151, 152, 154, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 167, 168, 169, 173, 174

Metodologías activas 184, 185, 186, 187, 189, 192

Modelos Multimodales 100

Morrison Formation 220, 228

## N

Nanoquímica 32, 48

## O

Odd-order differential operators 1, 16

Odontología 206, 207, 208

## P

Percepción 67, 138, 140, 143, 144, 147, 148, 149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 160, 161, 162, 176, 188, 189

Periodic Sobolev spaces 1, 16

Potencial de Lennard-Jones 17, 18, 28, 29

Private collections 220

Procesamiento de Lenguaje Natural 84, 88, 107, 112

Psicología 127, 165, 166, 167, 169, 173, 174

Python 84, 85, 87, 88, 89, 91, 97

## Q

Química Ambiental 183, 184, 185, 187, 188, 189, 192

Química de materiales 32, 48

## R

Reconocimiento de voz 84, 85, 86, 87, 88, 89, 94, 95, 96, 97, 98, 101, 102, 103, 108, 110

Redes Neuronales Convolucionales 99, 100, 101, 102, 104, 106, 113

Redes Neuronales Recurrentes 99, 100, 101, 102, 103, 106, 113

Región Ica 116, 119, 122

Responsabilidad profesional 175

Revisión sistemática 163, 194, 196, 197, 218

## S

Sauriermuseum Aathal 220, 221, 225, 229, 230


Science–policy collaboration 220

Sueño 194, 195, 196, 198, 199, 200, 201, 202, 203, 204, 205

## T

TENS 66, 67, 69, 83

Transformadores 99, 100, 101, 109, 111



**EDITORA  
ARTEMIS**

**2026**