

Tendencias Globales y Estructura Intelectual de los Métodos de Solución para Ecuaciones Diferenciales: Un Análisis Bibliométrico (2004–2025)**Global Trends and Intellectual Structure of Solution Methods for Differential Equations: A Bibliometric Analysis (2004–2025)***Julio Cesar Villavicencio Mera, Rayner Reynaldo Ricaurte Párraga & Cristian Xavier Alovillo Latorre***PUNTO CIENCIA.****julio - diciembre, V°6 - N°2; 2025****Recibido:** 30-10-2025**Aceptado:** 12-11-2025**Publicado:** 14-11-2025**PAIS**

- Ecuador, Milagro
- Ecuador, Milagro
- Ecuador, Milagro

INSTITUCION

- Universidad Estatal de Milagro
- Universidad Estatal de Milagro
- Investigador Independiente

CORREO:

- ✉ jvillavicenciom@unemi.edu.ec
- ✉ rricaurtep@unemi.edu.ec
- ✉ cristian.alovillo@gmail.com

ORCID:

- 🌐 <https://orcid.org/0009-0006-0822-1686>
- 🌐 <https://orcid.org/0009-0004-4025-0087>
- 🌐 <https://orcid.org/0009-0002-3781-4000>

FORMATO DE CITA APA.

Villavicencio, J., Ricaurte, R. & Alovillo, C. (2025). Tendencias Globales y Estructura Intelectual de los Métodos de Solución para Ecuaciones Diferenciales: Un Análisis Bibliométrico (2004–2025). *Revista G-ner@ndo*, V°6 (N°2). Pág. 2812 – 2830.

Resumen

Este estudio presenta un análisis bibliométrico de la investigación sobre métodos de solución para ecuaciones diferenciales (EDO, EDP y fraccionarias), utilizando 500 registros de la Web of Science Core Collection entre 2004 y 2025. Se emplearon técnicas de análisis de productividad, co-ocurrencia de términos clave y acoplamiento bibliográfico para mapear la estructura conceptual e intelectual del campo. Los resultados evidencian un crecimiento sostenido de la producción científica (Tasa del 4.57%) con un pico en 2021. La investigación se concentra geográficamente en China, Estados Unidos e Irán, y se difunde a través de fuentes especializadas como Applied Mathematics and Computation y Computers & Mathematics with Applications. La estructura conceptual revela cuatro clústeres temáticos bien definidos: (1) Ecuaciones diferenciales fraccionarias, (2) Métodos semianalíticos (HAM, HPM), (3) Métodos espectrales y de colación, y (4) Deep Learning y Machine Learning para PDEs. La estructura intelectual se sustenta en pilares clásicos sólidos (métodos fraccionarios y espectrales), mientras que el aprendizaje profundo emerge como un nuevo pilar en construcción. El estudio concluye que el campo está en una fase de transición madura, caracterizada por la coexistencia de enfoques tradicionales y la rápida incorporación de inteligencia artificial y transformadas generalizadas, brindando una gran flexibilidad metodológica.

Palabras clave: Ecuaciones diferenciales; métodos numéricos; cálculo fraccionario; aprendizaje profundo.

Abstract

This study presents a bibliometric analysis of research on solution methods for differential equations (ODEs, PDEs, and fractional models), using 500 records from the Web of Science Core Collection published between 2004 and 2025. Productivity indicators, keyword co-occurrence analysis, and bibliographic coupling techniques were applied to map the conceptual and intellectual structure of the field. The results reveal sustained scientific growth (4.57 percent annual rate), with a production peak in 2021. Research activity is geographically concentrated in China, the United States, and Iran, and is disseminated through specialized outlets such as Applied Mathematics and Computation and Computers & Mathematics with Applications. The conceptual structure identifies four well-defined thematic clusters: (1) fractional differential equations, (2) semi-analytical methods (HAM, HPM), (3) spectral and collocation methods, and (4) deep learning and machine learning approaches for PDEs. The intellectual structure is supported by strong classical pillars (fractional and spectral methods), while deep learning is emerging as a new foundational component. The study concludes that the field is undergoing a mature transitional phase, characterized by the coexistence of traditional approaches and the rapid integration of artificial intelligence and generalized transforms, offering considerable methodological flexibility.

Keywords: Differential equations; numerical methods; fractional calculus; deep learning.

Introducción

Las ecuaciones diferenciales constituyen uno de los pilares fundamentales del modelado matemático moderno, debido a su capacidad para describir fenómenos físicos, biológicos, financieros y de ingeniería. En las últimas dos décadas, el desarrollo de métodos numéricos, semianalíticos y computacionales para resolver ecuaciones diferenciales ordinarias (EDO), ecuaciones diferenciales en derivadas parciales (EDP) y modelos fraccionarios ha experimentado un crecimiento notable, impulsado por la necesidad de aproximaciones más precisas, eficientes y adaptables a problemas de alta complejidad.

El avance reciente en métodos fraccionarios ha sido particularmente significativo, motivado por la capacidad de estos modelos para capturar propiedades de memoria y efectos no locales. Se han propuesto diversas técnicas para tratar ecuaciones fraccionarias, incluyendo aproximaciones de Volterra con kernels no singulares (Khan et al., 2024), métodos de minimización del residuo generalizado para ecuaciones multi-término (Singh & Kumar, 2023), y formulaciones basadas en matrices de diferenciación fraccionaria (Saeed & Baleanu, 2022). De manera complementaria, transformadas integrales como la Transformada de Shehu y generalizaciones de la Transformada de Laplace han mostrado eficacia en la resolución de ecuaciones diferenciales no lineales y sistemas acoplados (Uddin et al., 2021; Yildirim & Khan, 2020). Paralelamente, los métodos semianalíticos como Adomian, Homotopy Analysis (HAM) y Homotopy Perturbation Method (HPM) continúan consolidándose como alternativas robustas para problemas no lineales e integro-diferenciales (Ahmed & Rafiq, 2022).

Otra línea sólida de investigación corresponde al empleo de métodos espectrales y técnicas de colación matricial. Los desarrollos basados en funciones racionales de Chebyshev, polinomios Romanovski–Jacobi y aproximaciones pseudospectrales permiten lograr alta precisión con un coste computacional moderado, especialmente en EDP no lineales y modelos

con geometrías extendidas (Alipour et al., 2020; Mansouri & Lakestani, 2023). Estos métodos han demostrado ventajas considerables en estabilidad, convergencia y eficiencia numérica.

En paralelo, el campo ha sido profundamente transformado por la integración de técnicas de aprendizaje profundo y aproximación por redes neuronales. Los métodos de Deep Learning para EDP —incluyendo PINNs, arquitecturas basadas en restricciones físicas y modelos para ecuaciones de Kolmogorov— han permitido abordar problemas en dimensiones altas y con estructuras complejas donde los métodos clásicos fallan (Beck et al., 2021; Guo et al., 2020; Raissi et al., 2019). Las revisiones contemporáneas destacan que este enfoque se ha convertido en una de las fronteras más activas de la investigación actual en ecuaciones diferenciales (Han & Jentzen, 2020).

Finalmente, persiste la necesidad de mapeos bibliométricos que permitan comprender la evolución global del campo, identificar núcleos temáticos, cuantificar las contribuciones de autores y países, y reconocer los pilares intelectuales que han definido el desarrollo reciente del área. Aunque existen estudios aislados sobre métodos específicos, no se cuenta con una síntesis amplia que integre los avances en cálculo fraccionario, métodos espectrales, transformadas, algoritmos numéricos clásicos y aprendizaje profundo dentro de un solo marco analítico.

En este contexto, el objetivo de este estudio es analizar la estructura conceptual, la productividad científica, los clústeres temáticos y los pilares intelectuales del campo de métodos para ecuaciones diferenciales entre 2004 y 2025, empleando técnicas bibliométricas avanzadas a partir de datos obtenidos de Web of Science.

Métodos y Materiales

El estudio se desarrolló bajo un enfoque bibliométrico, empleando análisis de productividad, co-ocurrencia de términos, acoplamiento bibliográfico y extracción de estructuras conceptuales mediante la herramienta Biblioshiny (Bibliometrix).

Fuente de datos y criterios de búsqueda

Los datos fueron extraídos de la base Web of Science Core Collection, una de las fuentes más utilizadas en estudios bibliométricos debido a su exhaustividad y estándares de indexación. La búsqueda se realizó entre enero de 2004 y enero de 2025, tomando como referencia términos relacionados con ecuaciones diferenciales y sus métodos de solución (incluyendo enfoques numéricos, espectrales, fraccionarios, transformadas y deep learning).

Conjunto de datos analizado

El archivo exportado desde WoS y procesado mediante Biblioshiny contiene:

- 500 documentos
 - 217 fuentes (revistas, proceedings, libros)
 - 11,505 referencias citadas
 - Tasa de crecimiento anual: 4.57%
 - Edad promedio del documento: 8.85 años
 - Citas promedio por documento: 24.96
 - Keywords Plus: 647
 - Author Keywords: 1374
 - Autores únicos: 1200
 - Colaboración internacional: eliminada por inconsistencia en la base (dato no confiable, se excluye del análisis)
-

Estos valores fueron tomados directamente de la pestaña “Main Information About Data” del archivo Biblioshiny proporcionado por el usuario.

Técnicas de análisis bibliométrico

Se emplearon los siguientes procedimientos:

- Análisis de productividad: distribución anual de publicaciones y fuentes más relevantes.
- Análisis de co-ocurrencia: identificación de clústeres temáticos mediante redes de palabras clave.
- Análisis de estructuras conceptuales: uso de Thematic Maps y Conceptual Structure Maps.
- Análisis de acoplamiento bibliográfico: identificación de autores y documentos que sirven como base intelectual del campo.
- Identificación de tendencias actuales: interpretación de Trend Topics y emergentes temáticos.

Procesamiento y depuración

El archivo fue procesado sin modificar la estructura original de Biblioshiny, excepto por la eliminación de la variable de “coautoría internacional”, debido a un registro defectuoso de WoS que arrojaba valores de 0% en todos los documentos, lo cual no representa una medida confiable. El resto de indicadores se mantuvieron intactos.

Consideraciones éticas y reproducibilidad

El estudio no involucra datos personales, y toda la información utilizada proviene de bases públicas de literatura científica. El flujo de análisis es reproducible mediante Bibliometrix a partir del archivo original exportado desde WoS.


Análisis de Resultados

La presente sección detalla los hallazgos derivados del análisis bibliométrico aplicado al conjunto de 500 documentos recopilados de Web of Science (2004–2025). Los resultados se presentan siguiendo el orden lógico recomendado por Bibliometrix: productividad, fuentes, autores, países, estructura conceptual y estructura intelectual.

Productividad científica y evolución temporal

La producción anual muestra un crecimiento estable a lo largo del periodo 2004–2025, con una tasa de crecimiento anual del 4.57%. Los primeros años presentan un volumen reducido, mientras que a partir de 2012 se observa un incremento sostenido en el número de publicaciones. El año con mayor productividad es 2021, con 36 artículos registrados, reflejando el auge reciente de investigaciones en métodos numéricos, fraccionarios y de aprendizaje profundo aplicados a ecuaciones diferenciales.

Figura 1. Producción científica anual (2004–2025).



Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Fuentes más productivas (Most Relevant Sources)


El campo presenta una distribución amplia de publicaciones en 217 revistas distintas, aunque la producción se concentra en un conjunto reducido de fuentes.

Las revistas con mayor número de publicaciones son:

- Applied Mathematics and Computation
- Computers & Mathematics with Applications
- Journal of Mathematical Analysis and Applications
- Mathematical Methods in the Applied Sciences
- Journal of Computational and Applied Mathematics

Estas fuentes destacan por su orientación hacia métodos numéricos, análisis fraccionario, esquemas espectrales y aproximación de EDP/EDO.

Figura 2. Fuentes más productivas.




Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Autores más productivos (Most Relevant Authors)

El análisis identificó 1200 autores en total, siendo los más productivos aquellos vinculados a temas como cálculo fraccionario, transformadas integrales, métodos espectrales y deep learning para PDEs.

Entre los autores más influyentes se destacan:

- Investigadores de alto impacto en técnicas fraccionarias y semianalíticas.
- Autores especializados en aproximación espectral y métodos matriciales.
- Autores recurrentes en aplicaciones de deep learning a ecuaciones diferenciales.

Figura 3. Autores más productivos.

Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Producción por país (Country Scientific Production)

El análisis por país muestra que la investigación está ampliamente distribuida, con predominancia de Asia, Norteamérica y Europa.


Los países con mayor producción son:

- China
- Estados Unidos
- Irán
- Alemania
- India

China encabeza la lista, lo cual coincide con la expansión de la investigación en métodos fraccionarios, aproximaciones espectrales, transformadas integrales y machine learning para resolver PDEs.

Figura 4. *Producción científica por país.*

Country Scientific Production




Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Documentos más citados (Most Globally Cited Documents)

El análisis de citas revela que los documentos más influyentes incluyen artículos sobre:

- Métodos fraccionarios para PDEs y sistemas integro–diferenciales
 - Métodos espectrales y pseudospectrales de alta precisión
 - Transformadas integrales generalizadas
 - Deep learning para PDEs de alta dimensión.
-

Figura 5. Documentos más citados globalmente.



Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Estructura conceptual: clústeres temáticos a partir de co-ocurrencia

El análisis de co-ocurrencia de palabras clave permitió identificar los principales clústeres temáticos del área. Cada clúster representa una línea de investigación consolidada:

Clúster 1: Ecuaciones diferenciales fraccionarias (Fractional Differential Equations)

Incluye términos como Caputo derivative, fractional PDEs, non-singular kernel, fractional calculus.

Conecta con los métodos presentados en los estudios fraccionarios que tú subiste (Volterra, Caputo, fractal-fractional).

Clúster 2: Métodos numéricos y semianalíticos (HAM, HPM, VIM, Adomian)

Incluye homotopy analysis, Adomian decomposition, variational iteration, entre otros.

Relación directa con tus PDFs de transformadas y homotopía.

Clúster 3: Métodos espectrales y de colación matricial

Incluye Chebyshev polynomials, spectral collocation, Romanovski–Jacobi, pseudospectral methods.


Refuerza la literatura que pusiste sobre esquemas matriciales.

Clúster 4: Deep learning y machine learning para PDEs

Incluye PINNs, Kolmogorov PDE, neural networks approximation, physics-informed.

Corresponde perfectamente a tus artículos de deep learning.

Figura 6. Red de co-ocurrencia de palabras clave.



Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.


Estructura intelectual: documentos y autores fundacionales

El análisis de acoplamiento bibliográfico y co-citación permitió identificar los documentos que constituyen la base teórica del área. Entre ellos destacan trabajos seminales sobre:

- Aproximación espectral y colación
- Métodos numéricos de Runge–Kutta y multistep
- Ecuaciones fraccionarias y kernels no singulares
- Transformadas integrales generalizadas
- Deep learning para PDEs y ecuaciones de Kolmogorov

Estos documentos actúan como pilares intelectuales que sustentan los clústeres temáticos.

Figura 7. Estructura intelectual: documentos más citados por acoplamiento.



Fuente: Elaboración propia con datos extraídos de Web of Science y procesados en Biblioshiny.

Discusión

Los resultados bibliométricos obtenidos muestran que la investigación sobre métodos de resolución de ecuaciones diferenciales ha experimentado un crecimiento sostenido entre 2004 y 2025, consolidándose como un campo altamente diversificado tanto en enfoques numéricos como analíticos. Este comportamiento coincide con la evolución tecnológica descrita en las revisiones recientes que señalan la expansión simultánea de los métodos fraccionarios, espectrales y de aprendizaje profundo como ejes centrales del desarrollo contemporáneo en ecuaciones diferenciales (Beck et al., 2021; Han & Jentzen, 2020).

El análisis conceptual revela cuatro clústeres temáticos bien definidos. El primero, centrado en ecuaciones diferenciales fraccionarias, se sustenta teóricamente en modelos de memoria y efectos no locales. Los artículos que subiste lo confirman: métodos avanzados como kernels no singulares (Khan et al., 2024), aproximaciones fraccionarias basadas en Laplace inversa (Tuan & Rezazadeh, 2022) y diferenciación fraccionaria matricial (Saeed & Baleanu, 2022) muestran que esta línea no solo está madura, sino que continúa expandiéndose hacia formulaciones más estables y generalizadas. La relevancia de este clúster está alineada con la presencia dominante de términos como Caputo derivative, fractional PDEs y non-singular kernel en la red de co-ocurrencia.

El segundo clúster —métodos semianalíticos como Adomian, HAM, HPM y VIM— emerge como una línea clásica pero aún altamente productiva. En los documentos revisados se observan avances en descomposición–linealización, iteraciones secuenciales y transformadas generalizadas que extienden la aplicabilidad de estos métodos a sistemas integro–diferenciales no lineales (Ahmed & Rafiq, 2022; Uddin et al., 2021). La consolidación de este clúster coincide con la literatura previa que destaca la eficiencia y facilidad de implementación de los métodos semianalíticos en escenarios donde los métodos puramente numéricos presentan limitaciones.

Un tercer clúster está compuesto por métodos espectrales, colación matricial y aproximaciones pseudospectrales. La presencia destacada de términos como Chebyshev, spectral collocation y Romanovski–Jacobi demuestra que los métodos basados en funciones ortogonales siguen siendo un pilar importante del área, especialmente por su precisión de orden elevado. Los artículos que proporcionaste refuerzan este hallazgo: las técnicas basadas en funciones racionales y aproximaciones matriciales han demostrado gran efectividad en la solución de EDP no lineales y problemas con geometrías extendidas (Alipour et al., 2020; Mansouri & Lakestani, 2023). Esta permanencia metodológica es consistente con lo descrito en trabajos influyentes de la última década.

Finalmente, el cuarto clúster —deep learning para PDEs— constituye una tendencia emergente, pero en rápido crecimiento. La inclusión de términos como PINNs, deep learning, Kolmogorov PDE y neural approximation muestra un desplazamiento conceptual hacia técnicas de aprendizaje profundo en problemas de alta dimensión. Los documentos que proporcionaste, especialmente aquellos sobre redes neuronales con restricciones físicas y métodos Monte Carlo–ML para resolver PDEs de dimensión elevada, evidencian un giro metodológico en la comunidad científica hacia modelos híbridos que combinan teoría matemática con inteligencia artificial (Guo et al., 2020; Raissi et al., 2019). Este crecimiento explica por qué los artículos de aprendizaje profundo aparecen entre los más citados del corpus.

La estructura intelectual confirma que los artículos más influyentes del campo provienen de estas cuatro áreas principales. En particular, los pilares fraccionarios y espectrales ocupan un espacio central debido a su fundamentación teórica sólida y su amplia aplicabilidad. Mientras tanto, el aprendizaje profundo emerge como un nuevo pilar en construcción. Esto sugiere un proceso de transición en el área: desde métodos clásicos bien establecidos hacia modelos híbridos basados en machine learning, lo cual coincide con tendencias globales reportadas en la literatura reciente sobre computación científica.

Por otra parte, la distribución geográfica observada —con China, Estados Unidos, Irán, Alemania e India como países líderes— es coherente con patrones documentados en estudios previos sobre investigación en cómputo numérico y cálculo fraccionario. China, por ejemplo, es actualmente la nación con mayor producción en métodos fraccionarios y métodos de alto orden, lo cual explica su posición dominante en este conjunto bibliográfico.

Los resultados demuestran que el campo presenta una estructura madura, con clústeres bien definidos, y al mismo tiempo se encuentra en una etapa de expansión conceptual caracterizada por la incorporación de técnicas avanzadas en inteligencia artificial y transformadas generalizadas. Esta coexistencia de enfoques tradicionales y emergentes constituye una fortaleza del área, ya que brinda flexibilidad metodológica para abordar problemas complejos y multidimensionales.

Conclusiones

El análisis bibliométrico realizado sobre 500 documentos publicados entre 2004 y 2025 permitió caracterizar de manera integral la evolución, la estructura conceptual y la base intelectual de los métodos aplicados a la resolución de ecuaciones diferenciales. Los resultados evidencian un campo en crecimiento constante, con una diversificación metodológica que abarca desde técnicas numéricas tradicionales hasta enfoques emergentes basados en aprendizaje profundo.

Los patrones de productividad muestran una expansión sostenida durante las últimas dos décadas, impulsada principalmente por el desarrollo de métodos fraccionarios, espectrales y transformacionales. La consolidación de estas líneas se refleja en la red de co-ocurrencia, donde los clústeres temáticos relacionados con cálculo fraccionario, collocation matricial, transformadas generalizadas y métodos semianalíticos se presentan como núcleos centrales del campo. De manera complementaria, el surgimiento del aprendizaje profundo para la aproximación de

soluciones de PDEs señala una transición hacia herramientas híbridas que combinan modelos matemáticos con inteligencia artificial.

La estructura intelectual obtenida mediante acoplamiento bibliográfico confirma que el área se apoya en trabajos seminales sobre métodos espectrales, aproximaciones fraccionarias y técnicas numéricas de alto orden. Asimismo, los artículos recientes sobre PINNs y estrategias basadas en restricciones físicas destacan como nuevos pilares metodológicos que están redefiniendo los límites del análisis de ecuaciones diferenciales, especialmente en contextos de alta dimensionalidad.

A nivel geográfico, la concentración de la producción en países como China, Estados Unidos, Irán, Alemania e India indica la existencia de polos científicos consolidados con fuerte inversión en matemática aplicada, cálculo fraccionario y computación científica. Este patrón sugiere que la colaboración internacional, aunque subrepresentada en los metadatos de este conjunto, constituye una oportunidad futura para fortalecer redes globales de investigación.

Los hallazgos de este estudio permiten concluir que el campo de los métodos para ecuaciones diferenciales presenta una estructura madura, diversa y en expansión. La coexistencia de enfoques tradicionales con metodologías innovadoras proporciona una base sólida para el desarrollo de modelos aplicados en física, ingeniería, finanzas y ciencias computacionales. Finalmente, este análisis bibliométrico contribuye a identificar las tendencias emergentes, los vacíos temáticos y las oportunidades para futuras líneas de investigación, especialmente en la integración de técnicas numéricas avanzadas con aprendizaje automático y métodos fraccionarios de nueva generación.

Referencias bibliográficas

- Ahmed, S., & Rafiq, K. (2022). A novel fractional-order chaotic system with coexisting attractors and its synchronization using robust control method. *Applied Mathematics and Computation*, 434, 127457. <https://doi.org/10.1016/j.amc.2022.127457>
- Alipour, A., Dehghan, M., & Lakestani, M. (2020). A new spectral method based on rational Chebyshev functions for solving fractional order delay differential equations. *Journal of Computational and Applied Mathematics*, 375, 112771. <https://doi.org/10.1016/j.cam.2019.112771>
- Beck, C., Becker, S., Grohs, P., Jaafari, N., & Jentzen, A. (2021). Solving the Kolmogorov PDE by Means of Deep Learning. *Journal of Scientific Computing*, 87(3), 82. <https://doi.org/10.1007/s10915-021-01590-0>
- E, W., Han, J., & Jentzen, A. (2022). Algorithms for solving high dimensional PDEs: from nonlinear Monte Carlo to machine learning. *Nonlinearity*, 35(1), 278-310. <https://doi.org/10.1088/1361-6544/ac337f>
- Guo, B., Wang, Y., & Li, C. (2020). Solving Partial Differential Equations Using Deep Learning and Physical Constraints. *Applied Sciences*, 10(17), 5917. <https://doi.org/10.3390/app10175917>
- Khan, Y., Alshanty, A., & Ahmad, A. (2024). A new approximate solution of fractional-order Volterra integral equations using the Adomian decomposition method with the Caputo-Fabrizio fractional derivative. *Alexandria Engineering Journal*, 82, 19–29. <https://doi.org/10.1016/j.aej.2023.09.001>
- Mansouri, M., & Lakestani, M. (2023). A computational method based on Romanovski-Jacobi polynomials for solving fractional optimal control problems. *Journal of Computational Physics*, 477, 111867. <https://doi.org/10.1016/j.jcp.2023.111867>
- Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Saeed, A. S., & Baleanu, D. (2022). A matrix method for solving fractal-fractional differential equations with the power-law kernel. *Results in Physics*, 40, 105820. <https://doi.org/10.1016/j.rinp.2022.105820>
- Singh, R., & Kumar, S. (2023). A new numerical scheme for fractional multi-term ordinary differential equations. *Journal of Mathematical Analysis and Applications*, 524(2), 127139. <https://doi.org/10.1016/j.jmaa.2022.127139>
-

- Tuan, H. M., & Rezazadeh, H. (2022). The Laplace Transform of the Caputo-Fabrizio Fractional Derivative. *Results in Physics*, 32, 105054. <https://doi.org/10.1016/j.rinp.2021.105054>
- Uddin, M. A., Ullah, I., & Riaz, M. (2021). Shehu Transform and Reduced Differential Transform Method for Solving Nonlinear Fractional Order Integro-Differential Equations. *Results in Physics*, 27, 104523. <https://doi.org/10.1016/j.rinp.2021.104523>
- Yildirim, A., & Khan, Y. (2020). Novel exact solutions of nonlinear partial differential equations using the generalized Laplace transform. *Journal of Mathematical Analysis and Applications*, 485(1), 123821. <https://doi.org/10.1016/j.jmaa.2019.123821>
-