



Doi: <https://doi.org/10.70577/ASCE/1317.1345/2025>

**Recibido:** 2025-04-15

**Aceptado:** 2025-05-15

**Publicado:** 2025-06-26

**Modelado y simulación de sistemas mecánicos complejos mediante  
principios de la física aplicada en ingeniería**

*Modeling and simulation of complex mechanical systems using principles of  
applied physics in engineering.*

**Autor:**

**Julio César Morocho Orellana**

<https://orcid.org/0000-0001-9211-1856>

[jcmorocho@utmachala.edu.ec](mailto:jcmorocho@utmachala.edu.ec)

**Universidad Técnica de Machala**

**Cómo citar**

Morocho Orellana, J. C. (2025). Modelado y simulación de sistemas mecánicos complejos mediante principios de la física aplicada en ingeniería. ASCE, 4(2), 1317–1345.



## Resumen

El modelado y la simulación de sistemas mecánicos complejos representan un eje central en el desarrollo de soluciones innovadoras en ingeniería. Este artículo presenta una revisión sistemática y analítica del estado del arte en torno al modelado de mecanismos multicomponente, con énfasis en la integración de principios de la física aplicada y herramientas computacionales avanzadas. Se exploran los fundamentos teóricos del modelado dinámico-estructural, desde las leyes de Newton y la mecánica lagrangiana, hasta la mecánica de materiales y la teoría de vibraciones. Asimismo, se abordan técnicas modernas de simulación, como el análisis modal, la cinemática inversa y la co-simulación multidominio. La investigación identifica los principales enfoques metodológicos modelado basado en ecuaciones, modelado basado en datos e híbridos, así como las herramientas más utilizadas, como MATLAB, ANSYS, SolidWorks y Adams. Los resultados evidencian una tendencia hacia la adopción de modelos híbridos que combinan la precisión de la física con la adaptabilidad del aprendizaje automático, destacándose enfoques como PINNs, PINODE y los gemelos digitales. Se discuten los criterios de validación más efectivos y se identifican desafíos metodológicos persistentes, como la sensibilidad al ruido, la escalabilidad y la representatividad de fenómenos complejos. Finalmente, se proponen líneas de investigación futura orientadas a la mejora de la precisión, eficiencia computacional y aplicabilidad de los modelos físicos en contextos reales de ingeniería.

**Palabras claves:** Modelado Mecánico, Simulación Dinámica, Física Aplicada, Sistemas Complejos, Gemelos Gigitales, Redes Neuronales, Herramientas Computacionales.



## Abstract

The modeling and simulation of complex mechanical systems play a central role in the development of innovative engineering solutions. This article provides a systematic and analytical review of the state of the art in modeling multicomponent mechanisms, with a focus on integrating applied physics principles and advanced computational tools. The study explores theoretical foundations of dynamic-structural modeling, ranging from Newton's laws and Lagrangian mechanics to material mechanics and vibration theory. It also addresses modern simulation techniques such as modal analysis, inverse kinematics, and multidomain co-simulation. The research identifies key methodological approaches equation-based, data-driven, and hybrid models—as well as the most commonly used tools, including MATLAB, ANSYS, SolidWorks, and Adams. The findings reveal a trend toward hybrid models that combine the precision of physics with the flexibility of machine learning, highlighting approaches such as PINNs, PINODE, and digital twins. Effective validation criteria are discussed, along with persistent challenges such as noise sensitivity, computational scalability, and the faithful representation of complex phenomena. Finally, the study outlines future research directions aimed at enhancing model accuracy, computational efficiency, and practical applicability in real-world engineering contexts.

**Keywords:** mechanical modeling, dynamic simulation, applied physics, complex systems, digital twins, neural networks, computational tools.



## Introducción

El estudio y la representación de sistemas mecánicos complejos mediante modelado y simulación constituyen un componente esencial en el desarrollo de soluciones ingenieriles avanzadas. En el contexto actual, donde la eficiencia, la precisión y la confiabilidad son exigencias críticas en los procesos de diseño y manufactura, estas herramientas permiten predecir, analizar y optimizar el comportamiento dinámico y estructural de mecanismos sometidos a diversas condiciones de carga, movimiento y entorno. La simulación computacional, respaldada por modelos físicos rigurosos, ha transformado la manera en que se abordan los desafíos en ingeniería, al ofrecer un entorno virtual donde se pueden explorar múltiples escenarios sin incurrir en los altos costos ni en los riesgos inherentes a la experimentación directa.

El modelado mecánico implica la formulación de ecuaciones que describen el movimiento, las fuerzas internas y externas, así como las restricciones cinemáticas y dinámicas de un sistema, utilizando principios fundamentales de la física aplicada, como las leyes de Newton, la conservación de la energía y el análisis de esfuerzos. La simulación, por su parte, permite resolver estas ecuaciones de manera numérica, generando representaciones gráficas y analíticas que facilitan la interpretación del comportamiento del sistema. Esta combinación metodológica permite no solo validar diseños, sino también identificar fallas potenciales, mejorar configuraciones geométricas y seleccionar materiales adecuados, todo ello antes de construir un prototipo físico.

La creciente complejidad de los sistemas mecánicos en sectores como la robótica, la mecatrónica, la industria automotriz, la aeronáutica y la biomecánica ha impulsado el desarrollo de nuevas técnicas de modelado que incorporan múltiples grados de libertad, acoplamientos no lineales, efectos térmicos y vibracionales, entre otros aspectos. Por tanto, la formación de competencias técnicas en el uso de herramientas de simulación como MATLAB/Simulink, ANSYS, SolidWorks, o Adams, resulta indispensable para los profesionales de la ingeniería, ya que les permite enfrentar con solvencia los retos de diseño y análisis mecánico con un enfoque multidisciplinario y orientado a la innovación.

En esta línea, la presente investigación tiene como propósito realizar una revisión sistemática y analítica del estado del arte en torno al modelado y la simulación de sistemas mecánicos complejos, fundamentada en los principios de la física aplicada en ingeniería. El objetivo es identificar, a través del análisis crítico de la literatura especializada, los enfoques metodológicos más relevantes, las herramientas computacionales comúnmente utilizadas, y los avances recientes en la representación y análisis dinámico-estructural de sistemas mecánicos. Esta revisión permitirá establecer una base teórica sólida sobre los fundamentos físicos y matemáticos que sustentan el modelado de mecanismos complejos, así como clasificar las técnicas de simulación aplicadas en diversos contextos industriales y académicos. Del mismo modo, se evaluarán los criterios de validación empleados en estudios previos, con el fin de determinar los niveles de precisión alcanzados y su aplicabilidad en escenarios reales. A partir de esta indagación, se buscará destacar las tendencias emergentes, identificar vacíos de conocimiento y proponer líneas de investigación futura orientadas a optimizar el diseño, funcionamiento y confiabilidad de los sistemas mecánicos en el ámbito de la ingeniería moderna.

### **Sistemas mecánicos complejo**

Los sistemas mecánicos complejos se caracterizan por su alta densidad estructural y funcional, integrando múltiples grados de libertad, interacciones dinámicas no lineales y la coexistencia de diversos dominios físicos, como el mecánico, térmico, eléctrico e hidráulico (Al-Furjan et al., 2022). Estas configuraciones requieren enfoques de análisis integradores, ya que su comportamiento no puede preverse mediante métodos lineales o simplificaciones convencionales. Su estudio demanda un tratamiento riguroso que contemple tanto las interdependencias entre componentes como las respuestas emergentes ante estímulos externos, lo que hace indispensable la aplicación de herramientas avanzadas de modelado y simulación (Fu et al., 2023).

En el contexto de la ingeniería moderna, el modelado representa una herramienta crítica para la conceptualización, diseño y validación de sistemas mecánicos. A través de modelos formales, es posible anticipar el desempeño funcional de mecanismos antes de su construcción física, optimizando recursos y minimizando errores durante la fase de implementación (Gao et al., 2021). Este proceso no solo permite simular condiciones de

operación reales, sino que también facilita la evaluación de variables estructurales, dinámicas y de carga, generando soluciones más eficientes, sostenibles y alineadas con los estándares de confiabilidad industrial. De esta forma, el modelado actúa como puente entre la teoría y la aplicación práctica, asegurando decisiones fundamentadas en datos y predicciones robustas (Bishara et al., 2023).

Los modelos empleados en la ingeniería mecánica pueden clasificarse, en términos generales, en físicos, matemáticos y computacionales. Los modelos físicos reproducen experimentalmente el comportamiento del sistema a escala real o reducida; los matemáticos emplean ecuaciones para representar relaciones funcionales entre variables; y los modelos computacionales utilizan algoritmos y simulaciones para resolver sistemas complejos que no pueden abordarse analíticamente (Ghadami y Epureanu, 2022). Asimismo, es posible diferenciar entre modelos deterministas, que describen comportamientos bajo condiciones exactas y predecibles, y modelos estocásticos, que introducen componentes probabilísticos para representar fenómenos con variabilidad inherente. Esta categorización permite seleccionar el enfoque más adecuado según la naturaleza del sistema, el objetivo del análisis y las limitaciones de tiempo, recursos o precisión (Mattsson et al., 2020).

### **Principios de la física aplicada en el modelado de mecanismos**

Las leyes del movimiento de Newton constituyen uno de los pilares fundamentales en el modelado de sistemas mecánicos complejos. Estas leyes permiten establecer relaciones cuantitativas entre las fuerzas aplicadas sobre un cuerpo, su masa y la aceleración resultante, lo que facilita la predicción precisa del comportamiento dinámico de cuerpos rígidos y partículas (Yan et al., 2022). En contextos ingenieriles, su aplicación resulta esencial para analizar trayectorias, calcular reacciones dinámicas y evaluar la evolución temporal de sistemas bajo diversas condiciones de carga. Este enfoque proporciona una base confiable para representar interacciones físicas de manera directa y eficaz (Erdemir et al., 2020).

Complementando este marco clásico, la mecánica analítica ofrece una perspectiva más generalizada y matemática para abordar el comportamiento de sistemas mecánicos con restricciones. Las formulaciones de Lagrange y Hamilton permiten reducir la complejidad de los modelos al utilizar coordenadas generalizadas, evitando el tratamiento individualizado de



fuerzas y momentos para cada componente (Wang et al., 2022). Esta metodología resulta especialmente útil en sistemas con múltiples grados de libertad y vínculos no holonómicos, ya que permite establecer ecuaciones de movimiento más compactas y adaptables a herramientas computacionales avanzadas. Su implementación en entornos de simulación facilita la integración con algoritmos numéricos y mejora la eficiencia del análisis (Choi et al., 2021).

La teoría de vibraciones mecánicas añade otra dimensión crítica al estudio de sistemas complejos, al enfocarse en la respuesta dinámica frente a excitaciones periódicas, armónicas o aleatorias (Norrish et al., 2021). Mediante esta teoría, es posible identificar fenómenos como la resonancia, los modos normales de vibración y el efecto del amortiguamiento, aspectos fundamentales para garantizar la estabilidad estructural y funcionalidad de mecanismos sometidos a cargas variables. El análisis vibracional no solo permite prevenir fallos prematuros por fatiga, sino que también contribuye a optimizar diseños mecánicos al reducir la transmisión de vibraciones no deseadas y prolongar la vida útil de los componentes (Kohtz et al., 2022).

Por su parte, la mecánica de materiales y la teoría del continuo proporcionan los fundamentos necesarios para describir con precisión el comportamiento interno de los cuerpos deformables (Liu et al., 2020). Estas disciplinas permiten analizar distribuciones de tensiones y deformaciones bajo distintos regímenes de carga, considerando tanto la elasticidad como la plasticidad, así como propiedades viscoelásticas en materiales más complejos. Esta perspectiva es clave para el diseño estructural, ya que garantiza que los modelos representen adecuadamente la interacción entre geometría, propiedades del material y condiciones de frontera. La incorporación de estos principios en la simulación de sistemas mecánicos complejos asegura un enfoque integral que vincula la dinámica con la resistencia estructural, mejorando la confiabilidad y el desempeño del diseño final (Lissenden, 2021).

### **Herramientas computacionales para simulación**

En el contexto del modelado y simulación de sistemas mecánicos complejos, el uso de software especializado representa un recurso indispensable para abordar de manera eficiente fenómenos físicos multidimensionales. Herramientas como MATLAB/Simulink, ANSYS,



SolidWorks, MSC Adams y Abaqus se han consolidado como plataformas clave en entornos académicos e industriales (Georgopoulos et al., 2021). Cada una de estas aplicaciones ofrece funcionalidades particulares orientadas a la resolución de problemas específicos, desde el análisis dinámico multibody y simulaciones estructurales, hasta la integración de sistemas de control y la validación mediante prototipos virtuales. Su capacidad para representar condiciones reales, modelar geometrías complejas y acoplar distintos dominios físicos las convierte en aliados estratégicos para la ingeniería moderna (Amini et al., 2023).

El potencial de estas plataformas está respaldado por la implementación de métodos numéricos avanzados que permiten resolver ecuaciones diferenciales parciales y sistemas algebraicos complejos (Willard et al., 2022). Entre los más empleados se encuentran el método de elementos finitos (FEM), ampliamente utilizado para el análisis estructural, térmico y de vibraciones; el método de diferencias finitas (FDM), que facilita la discretización de ecuaciones en mallas regulares, y el método de volúmenes finitos (FVM), común en simulaciones de dinámica de fluidos (Zhang et al., 2021). Asimismo, las técnicas de integración numérica y los algoritmos de optimización permiten refinar los modelos en tiempo real y mejorar la eficiencia del diseño, facilitando la convergencia hacia soluciones robustas incluso en escenarios altamente no lineales (Csaba y Porod, 2020).

No obstante, el empleo de estas herramientas también conlleva ciertas limitaciones que deben ser cuidadosamente consideradas. Si bien ofrecen un alto grado de precisión, esta suele estar condicionada por la calidad del mallado, el tipo de formulación numérica y los recursos computacionales disponibles (Nikolayev, 2021). Además, aspectos como la velocidad de cálculo y la escalabilidad varían significativamente entre plataformas, influyendo directamente en la viabilidad del análisis para sistemas de gran escala o con múltiples dominios físicos acoplados. Pese a ello, la aplicabilidad en casos reales sigue siendo elevada, especialmente cuando se integran conocimientos teóricos sólidos y criterios de validación adecuados. Esta dualidad entre capacidad técnica y restricciones operativas obliga a una selección crítica de la herramienta según los objetivos específicos del proyecto de ingeniería (Zhang et al., 2021).

### **Técnicas de simulación y representación dinámica-estructural**

En el estudio de sistemas mecánicos complejos, la simulación de cuerpos rígidos y deformables constituye una técnica esencial para comprender el comportamiento físico bajo diversas condiciones de carga (Zohdi, 2020). Los modelos de cuerpos rígidos permiten analizar movimientos sin considerar deformaciones internas, siendo útiles en mecanismos articulados o robótica. Por otro lado, los modelos deformables incorporan el análisis de tensiones, deformaciones y propiedades materiales, fundamentales en estructuras flexibles o sometidas a esfuerzos dinámicos significativos (Stern et al., 2020). En escenarios más exigentes, se emplean enfoques híbridos y multiescala que integran ambos tipos de comportamiento, permitiendo simular interacciones físicas complejas con mayor realismo y precisión (Guo et al., 2022).

Complementando esta aproximación, el análisis modal y dinámico se utiliza para examinar la respuesta estructural frente a estímulos externos, como vibraciones, impactos o cargas variables en el tiempo. El análisis modal identifica las frecuencias naturales del sistema y sus modos de vibración, información crucial para evitar resonancias perjudiciales (Vadyala et al., 2022). A su vez, el análisis dinámico ofrece una visión temporal de la respuesta del sistema ante diferentes condiciones operativas, ayudando a anticipar comportamientos inestables o no deseados. Estas técnicas permiten optimizar tanto el diseño estructural como la vida útil del mecanismo simulado (Korner et al., 2020).

Finalmente, las representaciones gráficas y cinemáticas enriquecen el proceso de simulación al proporcionar herramientas visuales y analíticas que facilitan la interpretación de los resultados. La cinemática inversa, por ejemplo, permite calcular las posiciones articulares necesarias para alcanzar una trayectoria deseada, lo que resulta clave en robótica y biomecánica (Vasudevan et al., 2021). Asimismo, los diagramas de cuerpo libre ayudan a descomponer las fuerzas que actúan sobre cada componente, facilitando el análisis mecánico detallado. Las simulaciones animadas, por su parte, ofrecen representaciones dinámicas del comportamiento de sistemas mecánicos en movimiento, permitiendo validar modelos teóricos y comunicar resultados de forma más accesible e intuitiva (Papazoglou et al., 2022).

### **Enfoques metodológicos y estrategias de modelado**



En el ámbito del modelado de sistemas mecánicos complejos, dos enfoques predominantes han sido ampliamente utilizados: el modelado basado en ecuaciones y el modelado basado en datos. El primero se fundamenta en leyes físicas y principios matemáticos que describen el comportamiento del sistema mediante ecuaciones diferenciales, algebraicas o constitutivas (Liu et al., 2022). Este enfoque ofrece alta transparencia y predictibilidad en escenarios bien comprendidos. Por otro lado, el modelado basado en datos se apoya en técnicas de inteligencia artificial y aprendizaje automático, permitiendo capturar patrones complejos y no lineales directamente desde datos experimentales o simulados. Esta metodología resulta especialmente útil cuando los modelos físicos son difíciles de formular o cuando se desea mejorar la precisión en contextos con incertidumbre o gran variabilidad (Mattsson et al., 2020).

Para abordar fenómenos multidisciplinarios, las técnicas de co-simulación emergen como una estrategia potente que permite la integración sinérgica de diferentes dominios físicos, tales como interacciones termo-mecánicas, electro-mecánicas o fluido-estructurales (Legaard et al., 2023). Este enfoque favorece una representación integral del sistema mediante la combinación de modelos especializados que operan en paralelo y se comunican en tiempo real durante el proceso de simulación. De esta manera, se preserva la fidelidad física de cada subsistema, mientras se consigue una solución acoplada que refleja con mayor realismo las condiciones operativas del entorno ingenieril (Csaba y Porod, 2020).

A lo largo del ciclo de diseño, la complejidad del modelo debe adaptarse a las necesidades específicas de cada fase. En este contexto, el modelado multi-fidelidad se presenta como una técnica estratégica que emplea representaciones de distintos niveles de detalle, desde modelos conceptuales simplificados hasta simulaciones altamente detalladas. Este enfoque permite optimizar recursos computacionales, acelerar los procesos de validación temprana y facilitar la toma de decisiones en etapas críticas del desarrollo (Fu et al., 2023). Al alternar entre distintos niveles de abstracción, se logra un equilibrio efectivo entre precisión, costo computacional y tiempos de respuesta, lo que resulta fundamental para el diseño iterativo y la optimización de sistemas mecánicos complejos (Cunha et al., 2023).

### **Validación de modelos y criterios de precisión**



La validación de modelos constituye un proceso esencial en la ingeniería computacional, cuyo propósito es asegurar que la representación matemática o computacional del sistema reproduce con fidelidad el comportamiento real (Liu et al., 2020). Para lograrlo, se emplean diversos criterios que permiten contrastar los resultados del modelo con datos experimentales, simulaciones de referencia o condiciones límite establecidas. Este proceso implica no solo la verificación interna del modelo, sino también la evaluación externa de su capacidad para predecir con exactitud fenómenos observables bajo diferentes escenarios operativos (Rui et al., 2022).

Entre los indicadores más utilizados para cuantificar el desempeño de un modelo se encuentran el error relativo, el coeficiente de correlación y el análisis de residuos. El error relativo proporciona una medida porcentual de la desviación entre el valor simulado y el valor observado, permitiendo una evaluación contextual de la precisión (Vadyala et al., 2022). Por su parte, el coeficiente de correlación analiza el grado de concordancia entre ambas series de datos, reflejando el nivel de ajuste del modelo a la realidad. Finalmente, el análisis de residuos revela patrones sistemáticos o aleatorios en las diferencias entre resultados previstos y observados, lo cual ayuda a detectar sesgos estructurales o errores en la formulación del modelo (Wagg et al., 2020).

Para garantizar la confiabilidad y la utilidad del proceso de validación, es fundamental aplicar buenas prácticas que aseguren la solidez metodológica del estudio. Entre ellas destacan la repetibilidad de los experimentos o simulaciones, lo que permite verificar la consistencia de los resultados obtenidos bajo las mismas condiciones; la trazabilidad, entendida como la posibilidad de reconstruir cada etapa del proceso desde la fuente de datos hasta el resultado final; y una documentación rigurosa que respalde cada decisión técnica tomada (Bishara et al., 2023). Estos elementos no solo fortalecen la credibilidad del modelo ante la comunidad científica e industrial, sino que también facilitan su reutilización, mejora y adaptación a nuevos contextos de aplicación (Guo et al., 2022).

## Método

Para el desarrollo de la presente investigación, se adoptó un enfoque cualitativo de tipo documental, sustentado en una revisión sistemática y analítica de la literatura especializada.

Este procedimiento metodológico permitió identificar, organizar y examinar de manera rigurosa el cuerpo teórico y técnico relacionado con el modelado y la simulación de sistemas mecánicos complejos, integrando los fundamentos de la física aplicada en el contexto ingenieril.

### ***Estrategia de búsqueda y selección de fuentes***

Se estableció un protocolo de búsqueda estructurado, utilizando bases de datos científicas reconocidas a nivel internacional, tales como Scopus, IEEE Xplore, ScienceDirect, SpringerLink y Web of Science. Las palabras clave y operadores booleanos empleados incluyeron combinaciones como: "*mechanical systems modeling*", "*complex dynamic simulation*", "*applied physics in engineering*", "*computational mechanics tools*", entre otras, delimitando los resultados a publicaciones entre los años 2021 y 2025. Los criterios de inclusión abarcaron artículos revisados por pares, libros especializados y tesis de posgrado que abordaran temáticas pertinentes a los objetivos planteados, priorizando aquellos estudios con aplicaciones prácticas y validez comprobada.

### ***Criterios de análisis y clasificación***

La información recopilada fue organizada en matrices temáticas, permitiendo una clasificación sistemática según: a) enfoque metodológico utilizado, b) herramientas computacionales aplicadas, c) nivel de complejidad del sistema simulado, d) criterios de validación implementados y e) área de aplicación (industria, robótica, biomecánica, entre otros). Este análisis permitió estructurar una visión comparativa y crítica, identificando tanto las convergencias como las divergencias en los enfoques abordados por distintos autores.

### ***Evaluación técnica y fundamentación teórica***

Posteriormente, se efectuó un examen profundo de los principios físicos y matemáticos que sustentan los modelos empleados, con especial atención a la formulación dinámica y estructural de sistemas multicomponente. Se revisaron las bases teóricas asociadas a la mecánica clásica, la dinámica de cuerpos rígidos y flexibles, así como los métodos numéricos utilizados para la resolución de ecuaciones diferenciales asociadas al comportamiento mecánico complejo.



### ***Validación y análisis crítico***

Se evaluaron los procedimientos de validación y verificación utilizados en los estudios seleccionados, considerando la precisión de los modelos frente a datos experimentales o simulaciones de referencia. Esta etapa permitió determinar la fiabilidad de las herramientas computacionales más recurrentes, así como sus limitaciones al ser aplicadas en contextos reales de ingeniería.

### ***Identificación de vacíos y proyección investigativa***

Finalmente, se integraron los hallazgos obtenidos en una síntesis crítica que permitió identificar las tendencias tecnológicas actuales, los desafíos metodológicos persistentes y las áreas temáticas escasamente abordadas. A partir de este diagnóstico, se formularon recomendaciones orientadas al desarrollo futuro de investigaciones que optimicen el desempeño, la eficiencia y la confiabilidad de los sistemas mecánicos complejos, contribuyendo al fortalecimiento del conocimiento aplicado en la ingeniería moderna.

**Tabla 1***Estudios de la revisión sistemática*

<b>Autor/año</b>	<b>Título</b>	<b>País</b>	<b>Objetivo</b>	<b>Metodología</b>	<b>Conclusión</b>
Guo, J., Baharvand, A., Tazeddinova, D., Habibi, M., Safarpour, H., Roco-Videla, A. y Selmi, A. (2022).	An intelligent computer method for vibration responses of the spinning multi-layer symmetric nanosystem using multi-physics modeling.	Irán	Aplicar técnicas de aprendizaje profundo, específicamente redes neuronales completamente conectadas, para estimar con alta precisión el rendimiento de frecuencia de nanodiscos multicapa giratorios montados sobre un sustrato viscoelástico, considerando los efectos dinámicos inducidos por la rotación.	Se utilizó una red neuronal profunda optimizada mediante un algoritmo basado en momento para determinar los parámetros óptimos del modelo.	Los resultados evidencian que variables como el número de capas de la base viscoelástica, la velocidad angular, el ángulo de laminado y los parámetros no locales y de escala influyen significativamente en la respuesta vibratoria del sistema.
Cardona, J. P., & Leal, J. J. (2024)	Evaluación del desarrollo de habilidades de modelado matemático en un curso de ecuaciones diferenciales	Colombia	Evaluar el impacto del uso de técnicas de modelado matemático en el desarrollo de habilidades analíticas en estudiantes de ingeniería durante un curso de ecuaciones diferenciales en	Se aplicó un diseño cuasi experimental con enfoque cuantitativo, conformando dos grupos: uno	La integración del modelado matemático en la enseñanza de ecuaciones diferenciales potencia



	ordinarias: un enfoque desde la ingeniería.		la Universidad Cooperativa de Colombia.	experimental y otro de control.	significativamente la capacidad de los estudiantes para identificar variables, parámetros y leyes físicas en sistemas reales, a diferencia de aquellos que reciben métodos tradicionales de enseñanza.
Legaard, C., Schranz, T., Schweiger, G., Drgoña, J., Falay, B., Gomes, C., ... & Larsen, P. (2023).	Constructing neural network based models for simulating dynamical systems.	Dinamarca	Analizar y resumir los enfoques actuales para la construcción de modelos de sistemas dinámicos mediante redes neuronales, destacando sus aplicaciones en física e ingeniería, así como identificar los principales desafíos y proponer áreas de investigación futuras.	Revisión de literatura científica relevante sobre modelado de sistemas dinámicos utilizando redes neuronales, con especial énfasis en los métodos de simulación numérica y su aplicación a problemas complejos.	El modelado basado en datos, particularmente mediante redes neuronales, se ha consolidado como una alternativa prometedora al modelado físico tradicional en sistemas dinámicos complejos.



Wagg, D. J., Worden, K., Barthorpe, R. J., & Gardner, P. (2020)	Digital twins: state-of-the-art and future directions for modeling and simulation in engineering dynamics applications.	Reino Unido	Realizar una revisión del estado del arte sobre la aplicación de los gemelos digitales en el campo de la dinámica de ingeniería, con énfasis en sus desafíos tecnológicos, procesos de síntesis y su aplicabilidad en sectores industriales clave.	Revisión exhaustiva de la literatura científica relacionada con los gemelos digitales aplicados a la dinámica, complementada con el análisis de un caso práctico basado en una estructura física a escala.	La implementación efectiva de estos sistemas requiere superar retos relacionados con la integración de modelos físicos y datos reales, la cuantificación de incertidumbre, la validación rigurosa y la estructuración de flujos de trabajo robustos.
Ritto, T. G., & Rochinha, F. A. (2021)	Digital twin, physics-based model, and machine learning applied to damage detection in structures.	Brasil	Desarrollar un marco simplificado para la implementación de gemelos digitales en sistemas dinámicos, mediante la integración de modelos físicos con técnicas de aprendizaje automático, con el fin de respaldar decisiones de ingeniería en tiempo real frente a escenarios de daño estructural.	Se construye un gemelo digital para una estructura dañada utilizando un modelo computacional discreto basado en la física, generando datos estocásticos que sirven para entrenar clasificadores de	El estudio demuestra que esta metodología es flexible y puede adaptarse a diversos escenarios, lo cual la hace aplicable a una amplia gama de sistemas dinámicos en ingeniería.



			aprendizaje automático.		
Liu, R., Dobriban, E., Hou, Z., & Qian, K. (2022)	Dynamic load identification for mechanical systems: A review.	China	Realizar una revisión exhaustiva de los métodos existentes para la identificación de cargas dinámicas en estructuras mecánicas, con especial atención a los enfoques que abordan problemas mal planteados, incertidumbre, sensibilidad al ruido y escalabilidad computacional, incorporando avances en estadística, ciencia de datos e inteligencia artificial.	Revisión sistemática de la literatura sobre técnicas de identificación de cargas dinámicas, incluyendo métodos clásicos basados en la física en dominios de frecuencia y tiempo, así como enfoques contemporáneos que integran modelos estadísticos, aprendizaje automático e inteligencia artificial.	Esta revisión proporciona directrices útiles para aplicaciones prácticas en estructuras complejas y sugiere que varios métodos revisados podrían extenderse a otros problemas inversos en ingeniería.
Rui, X., Zhang, J., Wang, X., Rong, B., He, B., & Jin, Z. (2022)	Multibody system transfer matrix method: the past,	China	Revisar de manera integral la teoría, algoritmos, herramientas de simulación y aplicaciones del Método	Se realiza un estudio de revisión que abarca los fundamentos	El MSTMM representa un avance significativo frente a los métodos dinámicos



	<p>the present, and the future.</p>		<p>de la Matriz de Transferencia de Sistemas Multicuerpo (MSTMM), destacando sus ventajas frente a los métodos dinámicos convencionales y analizando su potencial de expansión hacia nuevas áreas científicas y tecnológicas.</p>	<p>teóricos del MSTMM, su formulación matemática, el desarrollo de algoritmos asociados, y el análisis de herramientas de software empleadas en simulaciones dinámicas.</p>	<p>tradicionales debido a su eficiencia computacional, simplicidad de implementación y capacidad para modelar sistemas complejos sin recurrir a ecuaciones globales. Su aplicación exitosa en numerosos sistemas mecánicos respalda su fiabilidad. Se identifica un amplio potencial para su generalización en diversas disciplinas de la ciencia y la ingeniería, lo cual abre nuevas líneas de investigación futuras.</p>
<p>Roehrl, M. A., Runkler, T. A., Brandtstetter, V., Tokic, M., &amp;</p>	<p>Modeling system dynamics with physics-informed neural networks based on</p>	<p>Alemania</p>	<p>Proponer y validar un enfoque híbrido de modelado dinámico denominado PINODE, que integra ecuaciones</p>	<p>Se desarrolla un modelo híbrido que incorpora directamente las ecuaciones de</p>	<p>El modelo PINODE demuestra ser una herramienta efectiva para la identificación de</p>



Obermayer, S. (2020).	Lagrangian mechanics.		diferenciales basadas en la física con redes neuronales profundas, con el fin de superar las limitaciones de los métodos tradicionales basados en primeros principios o exclusivamente en datos.	movimiento derivadas de la mecánica de Lagrange dentro de la arquitectura de una red neuronal profunda.	sistemas dinámicos, al combinar las ventajas del conocimiento físico con la flexibilidad del aprendizaje automático. Ofrece alta precisión, buena eficiencia con cantidades reducidas de datos y garantiza la plausibilidad física, lo que lo convierte en un enfoque prometedor para aplicaciones en control e ingeniería de sistemas mecánicos.
Cunha, B. Z., Droz, C., Zine, A. M., Foulard, S., & Ichchou, M. (2023).	A review of machine learning methods applied to structural dynamics and vibroacoustic.	Francia	Analizar la aplicación de algoritmos de aprendizaje automático (ML) en tres áreas clave de la dinámica estructural y vibroacústica (SD&V): el monitoreo de la salud estructural, el control activo de ruido y vibración, y el diseño de productos	Se realiza un estudio comparativo de diferentes metodologías de ML aplicadas a tres problemas clásicos de SD&V. En el monitoreo	El aprendizaje automático ofrece ventajas significativas en SD&V al permitir modelado directo desde datos, sin necesidad de una representación física completa. Su



vibroacústicos, evaluando su efectividad frente a métodos tradicionales.

estructural, se emplean técnicas de extracción de características y diagnóstico de fallas.

aplicación en monitoreo estructural, control activo y diseño vibroacústico ha demostrado mejoras en eficiencia, diagnóstico y capacidad predictiva. Sin embargo, se destacan limitaciones inherentes a cada metodología. La integración del ML con modelos físicos y el desarrollo de gemelos digitales se presenta como una vía prometedora para abordar desafíos actuales y avanzar en investigaciones futuras en el campo.

## Resultados

Los estudios revisados en el marco de esta investigación evidencian avances significativos en el modelado y la simulación de sistemas mecánicos complejos, gracias a la integración de técnicas de inteligencia artificial, modelado basado en datos, y principios de la física aplicada. En primer lugar, el trabajo de Cunha et al. (2023) permite comprender cómo los algoritmos de aprendizaje automático se han convertido en herramientas eficaces para abordar desafíos tradicionales en dinámica estructural y vibroacústica, al permitir la detección temprana de daños estructurales, optimizar sistemas de control activo de ruido y facilitar el diseño eficiente de productos vibroacústicos. Estos enfoques ofrecen ventajas respecto a los métodos clásicos al prescindir de representaciones físicas completas, centrándose en el análisis de datos directamente muestreados, lo cual resulta especialmente valioso en escenarios donde los modelos físicos son costosos o difíciles de desarrollar.

Por su parte, Roehrl et al. (2020) aportan un enfoque híbrido, el modelo PINODE, que incorpora ecuaciones diferenciales derivadas de la mecánica lagrangiana dentro de redes neuronales profundas. Este modelo ha demostrado alta precisión y eficiencia incluso con cantidades reducidas de datos, al tiempo que garantiza la coherencia física del sistema simulado. Tal integración de conocimiento físico y aprendizaje automático permite una identificación más robusta de sistemas dinámicos complejos, aportando herramientas viables para aplicaciones en ingeniería de control y diseño mecánico.

Los aportes de Ritto y Rochinha (2021) se centran en el desarrollo de marcos simplificados de gemelos digitales para la detección de daños estructurales en tiempo real. Su propuesta combina modelos físicos computacionales discretos con clasificadores de aprendizaje automático, lo que permite la generación de datos sintéticos y la toma de decisiones automatizadas en condiciones de daño estructural. Este enfoque resalta la flexibilidad y adaptabilidad de los gemelos digitales en el monitoreo de estructuras, reforzando su aplicabilidad en contextos dinámicos.

Wagg et al. (2020) complementan esta perspectiva al realizar una revisión exhaustiva sobre el estado del arte de los gemelos digitales en ingeniería dinámica. Su análisis subraya la necesidad de resolver desafíos clave como la validación de modelos, la integración de datos



reales, la cuantificación de incertidumbre y el desarrollo de flujos de trabajo robustos. Esta visión prospectiva resalta el papel de los gemelos digitales como elementos fundamentales en la convergencia entre simulación y monitoreo estructural avanzado.

El trabajo de Legaard et al. (2023) refuerza la utilidad de las redes neuronales como sustitutos eficientes en la simulación de sistemas dinámicos complejos, especialmente en contextos donde los métodos numéricos tradicionales presentan limitaciones computacionales. Su revisión establece las bases para futuras líneas de investigación dirigidas a la mejora de la capacidad predictiva, interpretabilidad y estabilidad de estos modelos de red.

En el campo de la dinámica multicuerpo, Rui et al. (2022) destacan las ventajas del Método de la Matriz de Transferencia de Sistemas Multicuerpo (MSTMM), al ofrecer eficiencia computacional, simplicidad de implementación y mayor capacidad de modelado frente a métodos convencionales. Su revisión propone extender el uso de esta metodología hacia disciplinas emergentes de la ingeniería, reforzando su valor como técnica de simulación mecánica avanzada.

Por último, Liu et al. (2022) y Guo et al. (2022) brindan una visión integral sobre la identificación de cargas dinámicas y la predicción del comportamiento vibratorio en sistemas mecánicos, respectivamente. Sus contribuciones subrayan la importancia de abordar la incertidumbre, el ruido y la escalabilidad en los modelos dinámicos mediante técnicas de estadística avanzada, redes neuronales profundas y herramientas de optimización. Estos avances permiten simular con mayor fidelidad las condiciones operacionales reales de estructuras complejas, incrementando la precisión de los modelos físicos y fortaleciendo su aplicabilidad en entornos industriales.

En conjunto, los resultados evidencian que el modelado y la simulación de sistemas mecánicos complejos se están transformando gracias a la convergencia entre física aplicada, inteligencia artificial y tecnologías digitales emergentes. Los autores revisados aportan soluciones metodológicas robustas, modelos híbridos con validez física y herramientas digitales que permiten avanzar hacia sistemas de ingeniería más predictivos, adaptativos y eficientes, sentando las bases para el desarrollo de tecnologías más resilientes en el ámbito de la ingeniería mecánica.



## Discusión

Los hallazgos revisados revelan una transición paradigmática en el modelado de sistemas mecánicos complejos, que va desde métodos tradicionales fundamentados exclusivamente en ecuaciones físicas hacia enfoques híbridos y basados en datos, destacándose el papel creciente de las redes neuronales profundas, los gemelos digitales y los métodos informados por la física (PINNs). Esta evolución metodológica responde a la necesidad de representar con mayor precisión fenómenos no lineales, dinámicas transitorias complejas y condiciones límite variables que desafían los supuestos de los modelos clásicos.

Los estudios revisados coinciden en que la incorporación de conocimiento físico dentro de la arquitectura de las redes neuronales, como en el caso de los modelos PINODE, permite preservar la plausibilidad de las leyes de conservación y garantiza consistencia física, incluso en contextos donde los datos experimentales son escasos o ruidosos. Esta combinación proporciona no solo mayor precisión predictiva, sino también interpretabilidad y generalización en contextos reales de ingeniería.

El uso de técnicas de aprendizaje automático en la dinámica estructural y vibroacústica ha demostrado su eficacia en tareas como la detección de daños, la predicción de respuestas dinámicas y el diseño de soluciones de control. No obstante, los autores también advierten que estas metodologías aún presentan desafíos críticos, como la necesidad de grandes volúmenes de datos etiquetados, la sensibilidad al ruido y la limitada capacidad de extrapolación fuera del dominio de entrenamiento. Frente a ello, la integración con modelos físicos se perfila como una estrategia viable para superar dichas limitaciones.

La revisión de métodos como el Multibody System Transfer Matrix Method (MSTMM) sugiere que ciertos enfoques computacionales basados en la física aún conservan ventajas significativas, particularmente en eficiencia algorítmica y simplicidad de implementación, lo que refuerza la idea de que el futuro del modelado no se orienta a la sustitución de paradigmas clásicos, sino a su convergencia con herramientas computacionales modernas.

Se destaca, además, la aplicabilidad creciente de los gemelos digitales como solución integral para el monitoreo en tiempo real, el mantenimiento predictivo y la toma de decisiones automatizadas en sistemas estructurales. Su implementación depende, sin embargo, de la



adecuada integración entre simulaciones físicas, sensores, algoritmos de IA y gestión de incertidumbre, lo cual demanda desarrollos multidisciplinarios y marcos normativos más robustos.

Finalmente, el papel del modelado matemático en la educación de ingeniería, como lo muestra el estudio colombiano, resalta la importancia de vincular formación teórica con problemas reales. Esto no solo fortalece competencias analíticas en los futuros ingenieros, sino que también facilita la apropiación de modelos físicos complejos mediante herramientas computacionales contemporáneas.

### **Conclusión**

El modelado y simulación de sistemas mecánicos complejos ha experimentado una transformación significativa mediante la integración de principios físicos con técnicas avanzadas de inteligencia artificial. Esta convergencia ha demostrado mejorar la precisión, la eficiencia y la aplicabilidad de los modelos en múltiples escenarios de la ingeniería moderna.

Los enfoques híbridos, como los modelos informados por la física y las redes neuronales integradas con ecuaciones dinámicas, representan una evolución metodológica que resuelve las limitaciones de los métodos puramente empíricos o exclusivamente físicos. Al incorporar conocimiento físico en el aprendizaje automático, se asegura la validez científica de las simulaciones, especialmente en condiciones no ideales o con datos incompletos.

Los resultados evidencian que la implementación de gemelos digitales, combinando sensores, modelado físico y aprendizaje automático, ofrece una herramienta poderosa para la supervisión continua y la predicción de fallos en sistemas estructurales complejos. Sin embargo, su adopción generalizada requerirá superar obstáculos técnicos y garantizar la interoperabilidad de sistemas digitales y físicos.

La revisión sistemática confirma que el desarrollo de modelos computacionales eficientes, como el MSTMM, mantiene su relevancia y abre nuevas perspectivas para su aplicación en disciplinas emergentes. Su robustez y adaptabilidad justifican su uso continuo como base para simulaciones complejas en la ingeniería mecánica.

En el ámbito educativo, la incorporación de estrategias de modelado matemático en cursos de ingeniería potencia significativamente las capacidades de análisis y abstracción de los estudiantes, alineando la formación académica con las exigencias tecnológicas actuales. Esto respalda la necesidad de reformular los planes de estudio en ingeniería con una orientación práctica y computacional más intensa.

En conjunto, los aportes de los autores revisados delimitan un panorama alentador para la investigación y aplicación del modelado físico-computacional, señalando líneas futuras centradas en la automatización del aprendizaje de modelos, el desarrollo de marcos híbridos de simulación y la expansión del uso de gemelos digitales hacia sectores industriales más amplios y complejos.

## Referencias

- Al-Furjan, M. S. H., Fereidouni, M., Habibi, M., Abd Ali, R., Ni, J., & Safarpour, M. (2022). Influence of in-plane loading on the vibrations of the fully symmetric mechanical systems via dynamic simulation and generalized differential quadrature framework. *Engineering with Computers*, 1-23. <https://link.springer.com/article/10.1007/s00366-020-01177-7>
- Amini, M., Sharifani, K., & Rahmani, A. (2023). Machine learning model towards evaluating data gathering methods in manufacturing and mechanical engineering. *International Journal of Applied Science and Engineering Research*, 15(2023), 349-362. [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4331917](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4331917)
- Bishara, D., Xie, Y., Liu, W. K., & Li, S. (2023). A state-of-the-art review on machine learning-based multiscale modeling, simulation, homogenization and design of materials. *Archives of computational methods in engineering*, 30(1), 191-222. <https://link.springer.com/article/10.1007/s11831-022-09795-8>
- Cardona, J. P., & Leal, J. J. (2024). Evaluación del desarrollo de habilidades de modelado matemático en un curso de ecuaciones diferenciales ordinarias: un enfoque desde la ingeniería. *Formación universitaria*, 17(2), 1-14. [https://www.scielo.cl/scielo.php?pid=S0718-50062024000200001&script=sci\\_arttext](https://www.scielo.cl/scielo.php?pid=S0718-50062024000200001&script=sci_arttext)
- Choi, Y. K., Kern, N. R., Kim, S., Kanhaiya, K., Afshar, Y., Jeon, S. H., ... & Im, W. (2021). CHARMM-GUI nanomaterial modeler for modeling and simulation of nanomaterial systems. *Journal of chemical theory and computation*, 18(1), 479-493. <https://pubs.acs.org/doi/abs/10.1021/acs.jctc.1c00996>



- Csaba, G., & Porod, W. (2020). Coupled oscillators for computing: A review and perspective. *Applied physics reviews*, 7(1). <https://pubs.aip.org/aip/apr/article/7/1/011302/997386>
- Cunha, B. Z., Droz, C., Zine, A. M., Foulard, S., & Ichchou, M. (2023). A review of machine learning methods applied to structural dynamics and vibroacoustic. *Mechanical Systems and Signal Processing*, 200, 110535. <https://www.sciencedirect.com/science/article/pii/S0888327023004430>
- Erdemir, A., Mulugeta, L., Ku, J. P., Drach, A., Horner, M., Morrison, T. M., ... & Myers Jr, J. G. (2020). Credible practice of modeling and simulation in healthcare: ten rules from a multidisciplinary perspective. *Journal of translational medicine*, 18(1), 369. <https://link.springer.com/article/10.1186/s12967-020-02540-4>
- Fu, C., Sinou, J. J., Zhu, W., Lu, K., & Yang, Y. (2023). A state-of-the-art review on uncertainty analysis of rotor systems. *Mechanical systems and signal processing*, 183, 109619. <https://www.sciencedirect.com/science/article/pii/S0888327022007087>
- Ghadami, A., & Epureanu, B. I. (2022). Data-driven prediction in dynamical systems: recent developments. *Philosophical Transactions of the Royal Society A*, 380(2229), 20210213. <https://royalsocietypublishing.org/doi/abs/10.1098/rsta.2021.0213>
- Gao, Y., Liu, X., Huang, H., & Xiang, J. (2021). A hybrid of FEM simulations and generative adversarial networks to classify faults in rotor-bearing systems. *ISA transactions*, 108, 356-366. <https://www.sciencedirect.com/science/article/pii/S0019057820303359>
- Georgopoulos, K., Emary, C., & Zuliani, P. (2021). Modeling and simulating the noisy behavior of near-term quantum computers. *Physical Review A*, 104(6), 062432. <https://journals.aps.org/pr/abstract/10.1103/PhysRevA.104.062432>
- Guo, J., Baharvand, A., Tazeddinova, D., Habibi, M., Safarpour, H., Roco-Videla, A., & Selmi, A. (2022). An intelligent computer method for vibration responses of the spinning multi-layer symmetric nanosystem using multi-physics modeling. *Engineering with Computers*, 38(Suppl 5), 4217-4238. <https://link.springer.com/article/10.1007/s00366-021-01433-4>
- Guo, Y., Wang, X., Shen, Y., Dong, K., Shen, L., & Alzalab, A. A. A. (2022). Research progress, models and simulation of electrospinning technology: A review. *Journal of Materials Science*, 1-47. <https://link.springer.com/article/10.1007/s10853-021-06575-w>
- Kohtz, S., Xu, Y., Zheng, Z., & Wang, P. (2022). Physics-informed machine learning model for battery state of health prognostics using partial charging segments. *Mechanical*



- Systems and Signal Processing*, 172, 109002.  
<https://www.sciencedirect.com/science/article/pii/S0888327022001807>
- Körner, C., Markl, M., & Koepf, J. A. (2020). Modeling and simulation of microstructure evolution for additive manufacturing of metals: a critical review. *Metallurgical and Materials Transactions A*, 51, 4970-4983.  
<https://link.springer.com/article/10.1007/s11661-020-05946-3>
- Legaard, C., Schranz, T., Schweiger, G., Drgoňa, J., Falay, B., Gomes, C., ... & Larsen, P. (2023). Constructing neural network based models for simulating dynamical systems. *ACM Computing Surveys*, 55(11), 1-34.  
<https://dl.acm.org/doi/abs/10.1145/3567591>
- Lissenden, C. J. (2021). Nonlinear ultrasonic guided waves—Principles for nondestructive evaluation. *Journal of Applied Physics*, 129(2).  
<https://pubs.aip.org/aip/jap/article/129/2/021101/158329>
- Liu, R., Dobriban, E., Hou, Z., & Qian, K. (2022). Dynamic load identification for mechanical systems: A review. *Archives of Computational Methods in Engineering*, 29(2), 831-863. <https://link.springer.com/article/10.1007/s11831-021-09594-7>
- Liu, X., Huang, H., & Xiang, J. (2020). A personalized diagnosis method to detect faults in gears using numerical simulation and extreme learning machine. *Knowledge-Based Systems*, 195, 105653.  
<https://www.sciencedirect.com/science/article/pii/S0950705120301039>
- Mattsson, S. E., Andersson, M., & Åström, K. J. (2020). Object-oriented modeling and simulation. In *CAD for control systems* (pp. 31-69). CRC Press.  
<https://www.taylorfrancis.com/chapters/edit/10.1201/9781003067146-2/object-oriented-modeling-simulation-sven-erik-mattsson-mats-andersson-karl-johan-%C3%A5str%C3%B6m>
- Nikolayev, V. S. (2021). Physical principles and state-of-the-art of modeling of the pulsating heat pipe: A review. *Applied Thermal Engineering*, 195, 117111.  
<https://www.sciencedirect.com/science/article/pii/S1359431121005512>
- Norrish, J., Polden, J., & Richardson, I. (2021). A review of wire arc additive manufacturing: development, principles, process physics, implementation and current status. *Journal of Physics D: Applied Physics*, 54(47), 473001.  
<https://iopscience.iop.org/article/10.1088/1361-6463/ac1e4a/meta>
- Papazoglou, E. L., Karkalos, N. E., Karmiris-Obratański, P., & Markopoulos, A. P. (2022). On the modeling and simulation of SLM and SLS for metal and polymer powders: a review. *Archives of Computational Methods in Engineering*, 1-33.  
<https://link.springer.com/article/10.1007/s11831-021-09601-x>



- Ritto, T. G., & Rochinha, F. A. (2021). Digital twin, physics-based model, and machine learning applied to damage detection in structures. *Mechanical Systems and Signal Processing*, 155, 107614. <https://www.sciencedirect.com/science/article/pii/S0888327021000091>
- Roehrl, M. A., Runkler, T. A., Brandtstetter, V., Tokic, M., & Obermayer, S. (2020). Modeling system dynamics with physics-informed neural networks based on Lagrangian mechanics. *IFAC-PapersOnLine*, 53(2), 9195-9200. <https://www.sciencedirect.com/science/article/pii/S2405896320328354>
- Rui, X., Zhang, J., Wang, X., Rong, B., He, B., & Jin, Z. (2022). Multibody system transfer matrix method: the past, the present, and the future. *International Journal of Mechanical System Dynamics*, 2(1), 3-26. <https://onlinelibrary.wiley.com/doi/abs/10.1002/msd2.12037>
- Stern, M., Arinze, C., Perez, L., Palmer, S. E., & Murugan, A. (2020). Supervised learning through physical changes in a mechanical system. *Proceedings of the National Academy of Sciences*, 117(26), 14843-14850. <https://www.pnas.org/doi/abs/10.1073/pnas.2000807117>
- Vadyala, S. R., Betgeri, S. N., Matthews, J. C., & Matthews, E. (2022). A review of physics-based machine learning in civil engineering. *Results in Engineering*, 13, 100316. <https://www.sciencedirect.com/science/article/pii/S2590123021001171>
- Vasudevan, R., Pilia, G., & Balachandran, P. V. (2021). Machine learning for materials design and discovery. *Journal of Applied Physics*, 129(7). <https://pubs.aip.org/aip/jap/article/129/7/070401/287201>
- Wagg, D. J., Worden, K., Barthorpe, R. J., & Gardner, P. (2020). Digital twins: state-of-the-art and future directions for modeling and simulation in engineering dynamics applications. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering*, 6(3), 030901. <https://asmedigitalcollection.asme.org/risk/article-abstract/6/3/030901/1081999>
- Wang, J., Li, Y., Gao, R. X., & Zhang, F. (2022). Hybrid physics-based and data-driven models for smart manufacturing: Modelling, simulation, and explainability. *Journal of Manufacturing Systems*, 63, 381-391. <https://www.sciencedirect.com/science/article/pii/S0278612522000541>
- Willard, J., Jia, X., Xu, S., Steinbach, M., & Kumar, V. (2022). Integrating scientific knowledge with machine learning for engineering and environmental systems. *ACM Computing Surveys*, 55(4), 1-37. <https://dl.acm.org/doi/abs/10.1145/3514228>
- Yan, B., Harp, D. R., Chen, B., Hoteit, H., & Pawar, R. J. (2022). A gradient-based deep neural network model for simulating multiphase flow in porous media. *Journal of*



*Computational Physics*, 463, 111277.  
<https://www.sciencedirect.com/science/article/pii/S0021999122003394>

Zhang, L., Zhou, L., & Horn, B. K. (2021). Building a right digital twin with model engineering. *Journal of Manufacturing Systems*, 59, 151-164.  
<https://www.sciencedirect.com/science/article/pii/S0278612521000455>

Zohdi, T. I. (2020). A machine-learning framework for rapid adaptive digital-twin based fire-propagation simulation in complex environments. *Computer Methods in Applied Mechanics and Engineering*, 363, 112907.  
<https://www.sciencedirect.com/science/article/pii/S0045782520300906>

**Conflicto de intereses:**

Los autores declaran que no existe conflicto de interés posible.

**Financiamiento:**

No existió asistencia financiera de partes externas al presente artículo.

**Agradecimiento:**

N/A

**Nota:**

El artículo no es producto de una publicación anterior.