

Ark: <https://n2t.net/ark:/87558/tekhne.29.1.1>

Análisis Comparativo de Metodologías para la Predicción de Propiedades Mecánicas de Materiales Compuestos

Sergio Gomez¹

sergio.gomezs@upb.edu.co¹

<https://orcid.org/0000-0002-6425-7062>¹

Universidad Pontificia Bolivariana, Colombia; Universidad Católica Andrés Bello, Venezuela¹

Resumen

La predicción precisa de las propiedades mecánicas de los materiales compuestos representa un desafío técnico significativo, debido a su compleja estructura interna y a la amplia variedad de combinaciones posibles entre matrices y refuerzos. Este trabajo tiene como objetivo analizar y comparar las principales metodologías empleadas para este propósito, agrupándolas según su enfoque. El estudio se basó en una revisión bibliográfica estructurada de la literatura publicada en el periodo 2020-2024, mediante la cual se identificaron y clasificaron las estrategias utilizadas en cuatro categorías: experimentales, analíticas, numéricas (particularmente el método de elementos finitos) y basadas en inteligencia artificial. Posteriormente, se realizó un análisis comparativo de sus beneficios y limitaciones, considerando criterios como precisión, costo, flexibilidad, requerimientos técnicos y capacidad predictiva. Los resultados muestran que, si bien los ensayos experimentales ofrecen alta fidelidad, presentan limitaciones en términos de costos y replicabilidad. Los modelos analíticos se destacan por su simplicidad y rapidez, aunque tienden a perder exactitud en sistemas más complejos. Las simulaciones numéricas permiten representar estructuras heterogéneas con gran detalle, pero demandan recursos computacionales significativos. Finalmente, los enfoques basados en inteligencia artificial demuestran un alto potencial para gestionar grandes volúmenes de datos y reconocer patrones complejos, aunque su eficacia depende en gran medida de la calidad y representatividad de los datos disponibles.

Palabras clave: Elementos finitos, Inteligencia artificial, Materiales compuestos, Predicción, Propiedades mecánicas

A Comparative Analysis of Methodologies for Predicting the Mechanical Properties of Composite Materials

Abstract

Accurately predicting the mechanical properties of composite materials is a significant technical challenge due to their complex internal structure and the wide variety of possible matrix-reinforcement combinations. This study aims to analyze and compare the primary methodologies employed for this purpose, categorizing them based on their approach. A structured review of literature published between 2020 and 2024 was conducted to identify and classify the strategies used into four categories: experimental, analytical, numerical (particularly the finite element method), and artificial intelligence-based. A comparative analysis of the benefits and limitations of these strategies was then conducted, considering criteria such as accuracy, cost, flexibility, technical requirements, and predictive capacity. The results show that although experimental tests offer high fidelity, they are limited in terms of cost and replicability. Analytical models are notable for their simplicity and speed, though they tend to lose accuracy in complex systems. Numerical simulations allow for the representation of heterogeneous structures in detail but require significant computational resources. Finally, artificial intelligence-based approaches demonstrate great potential for managing large volumes of data and recognizing complex patterns; however, their effectiveness largely depends on the quality and representativeness of the available data.

Keywords: Finite elements, artificial intelligence, composite materials, prediction, mechanical properties.

Análise Comparativa de Metodologias para a Previsão das Propriedades Mecânico de Materiais Compostos

Resumo

A previsão precisa das propriedades mecânicas dos materiais compósitos constitui um desafio técnico significativo, dado que estes apresentam uma estrutura interna complexa e uma vasta gama de combinações possíveis entre matrizes e reforços. O presente trabalho tem como objetivo analisar e comparar as principais metodologias utilizadas para esse efeito, agrupando-as consoante a respetiva abordagem. Para o efeito, foi realizada uma revisão bibliográfica estruturada da literatura publicada entre 2020 e 2024, tendo sido identificadas e classificadas as estratégias utilizadas em quatro categorias: experimentais, analíticas, numéricas (em particular, o método dos elementos finitos) e baseadas em inteligência artificial. Posteriormente, foi realizada uma análise comparativa dos respetivos benefícios e limitações, tendo em conta critérios como a precisão, o custo, a flexibilidade, os requisitos técnicos e a capacidade preditiva. Os resultados mostram que, embora os ensaios experimentais ofereçam uma elevada fidelidade, apresentam limitações em termos de custos e replicabilidade. Os modelos analíticos destacam-se pela sua simplicidade e rapidez, embora tendam a perder precisão em sistemas mais complexos. As simulações numéricas permitem representar estruturas heterogêneas com grande detalhe, mas exigem recursos informáticos significativos. Por fim, as abordagens baseadas em inteligência artificial demonstram um elevado potencial para gerir grandes volumes de dados e reconhecer padrões complexos, embora a sua eficácia dependa em grande medida da qualidade e representatividade dos dados disponíveis.

Palavras-chave: Elementos finitos, Inteligência artificial, Materiais compostos, Previsão, Propriedades mecânicas

I. INTRODUCCIÓN

Un material compuesto se define como la combinación de dos o más materiales distintos con el fin de mejorar sus propiedades mecánicas individuales [1].

La capacidad de diseñar y fabricar materiales compuestos de acuerdo con especificaciones precisas permite ajustar sus propiedades para cumplir con requisitos particulares. En este sentido, anticipar las propiedades mecánicas antes del proceso de fabricación resulta no solo deseable, sino fundamental. Este enfoque predictivo permite reducir tiempos de desarrollo, minimizar costos asociados a la experimentación física, y asegurar un desempeño adecuado en condiciones reales de operación. Además, facilita la toma de decisiones informadas en fases tempranas del diseño, contribuyendo a la eficiencia del ciclo completo de desarrollo de nuevos materiales [2].

La criticidad de la predicción de propiedades mecánicas se manifiesta de forma palpable en sectores de alta exigencia [3]. En el sector aeroespacial, el uso extensivo de compuestos reforzados con fibra de carbono se justifica por su excepcional relación resistencia-peso, lo cual incide directamente en la eficiencia del combustible y en la integridad estructural de aeronaves modernas; en la industria automotriz, la incorporación de materiales compuestos ligeros no solo permite reducciones de peso entre el 15 % y el 40 %, sino que también es clave para el desarrollo de vehículos eléctricos, al mejorar su autonomía y rendimiento [4]. Asimismo, en la construcción, la durabilidad, la resistencia a la corrosión y el comportamiento frente a cargas extremas de compuestos reforzados con fibras naturales o sintéticas son factores determinantes para garantizar la seguridad y longevidad de las estructuras [5]. Dado que errores en la predicción del comportamiento mecánico pueden derivar en fallos estructurales con consecuencias severas, es imperativo contar con modelos predictivos rigurosos, validados experimentalmente y basados en metodologías trazables y replicables.

No obstante, predecir con precisión el comportamiento mecánico de los materiales compuestos sigue siendo un desafío técnico considerable. La complejidad estructural derivada de su naturaleza heterogénea, la presencia de interfaces entre fases, la anisotropía inherente y la sensibilidad a las condiciones de procesamiento dificultan la formulación de modelos universales. A esto se suma la creciente variedad de

combinaciones posibles entre matrices (poliméricas, metálicas, cerámicas) y refuerzos (fibras naturales, sintéticas, nanopartículas), lo que exige enfoques versátiles y adaptativos [6].


En años recientes, el panorama de la predicción de propiedades mecánicas en materiales compuestos ha sido transformado por el auge de herramientas computacionales avanzadas. El desarrollo de modelos basados en inteligencia artificial, en particular técnicas de machine learning (aprendizaje automático), ha permitido identificar patrones complejos en grandes volúmenes de datos experimentales y simulados, facilitando predicciones más rápidas y reduciendo la dependencia de ensayos físicos costosos y prolongados [7]. Paralelamente, la simulación numérica mediante el Método de Elementos Finitos (MEF) ha evolucionado hacia enfoques multifísicos y multiescala, capaces de representar con mayor fidelidad el comportamiento anisótropo, la respuesta no lineal y los mecanismos de daño en estructuras compuestas [8].

Este avance tecnológico se refleja en el crecimiento exponencial de la producción científica sobre compuestos, con tendencias claras hacia soluciones sostenibles, como el desarrollo de compuestos termoplásticos reforzados con fibras naturales [9]. Este impulso global hacia materiales ligeros, reciclables y de bajo impacto ambiental ha coincidido con una proliferación de metodologías predictivas, desde modelos analíticos clásicos hasta estrategias basadas en datos [10], [11], [12]. Sin embargo, justamente esta diversidad de enfoques cada uno con sus ventajas y limitaciones inherentes subraya la necesidad urgente de una revisión que sintetice, compare y evalúe críticamente las estrategias más efectivas y viables para su implementación industrial.

Por tal razón el presente trabajo tiene como objetivo realizar una revisión bibliográfica estructurada de la literatura publicada en los últimos cinco años para analizar las principales estrategias empleadas para la predicción de propiedades mecánicas en materiales compuestos, clasificarlas según su fundamento teórico y aplicabilidad práctica, y evaluar rigurosamente sus beneficios, alcances y limitaciones.


II. METODOLOGÍA

En la Figura 1 se presenta de manera esquemática la metodología utilizada.

**Figura 1:** Metodología**A. Revisión bibliográfica**

Se realizó una búsqueda sistemática de literatura científica enfocada en metodologías para la predicción de propiedades mecánicas de materiales compuestos. Para garantizar la relevancia y calidad de los documentos seleccionados, se aplicaron criterios de inclusión estrictos: (i) publicaciones en español e inglés, (ii) artículos indexados en las áreas de Materiales e Ingeniería, excluyendo contenidos relacionados con Química, (iii) prioridad a artículos de investigación y de revisión, excluyendo actas de congresos por su menor profundidad metodológica, (iv) publicaciones correspondientes a los últimos cinco años (2020-2024). La búsqueda se llevó a cabo en la base de datos especializada Scopus.

La estrategia de búsqueda seguida en el estudio se resume en la Figura 2.

**Figura 2:** Búsqueda sistemática**B. Identificación y clasificación de metodologías**

Tras aplicar los criterios de inclusión y exclusión descritos, se seleccionaron 61 estudios para el análisis detallado. A partir de estos, se procedió a identificar y clasificar las metodologías reportadas según su enfoque. Para cada metodología se elaboró una síntesis que incluyó sus principios fundamentales, el contexto de aplicación y las técnicas computacionales o experimentales asociadas.

C. Análisis de beneficios y limitaciones

Se desarrolló una evaluación comparativa de las metodologías identificadas, considerando criterios como la precisión en la predicción de propiedades mecánicas, la facilidad de implementación y los requisitos computacionales o experimentales. Esta comparación fue enriquecida con un análisis crítico de la literatura revisada, lo que permitió identificar fortalezas, debilidades y aspectos a mejorar en cada enfoque.

Es importante destacar que, aunque el proceso de búsqueda se diseñó y ejecutó siguiendo un protocolo riguroso, transparente y reproducible, esta investigación se clasifica como una Revisión Bibliográfica Estructurada y no como una Revisión Sistemática formal. Esta distinción se fundamenta en el objetivo central del estudio: no se busca sintetizar evidencia cuantitativa mediante metaanálisis ni estimar efectos promedio, sino analizar, comparar y contextualizar las distintas metodologías predictivas empleadas en la literatura para modelar propiedades mecánicas en materiales compuestos.

III. RESULTADOS**A. Revisión bibliográfica**

La pregunta de investigación formulada en el estudio fue: ¿Cuáles son las metodologías para la predicción de las propiedades mecánicas de los materiales compuestos? A partir de este planteamiento, se procedió a la identificación de los términos clave que guiarían la búsqueda bibliográfica. Para este fin, se utilizaron herramientas de inteligencia artificial (Copilot, Gemini y ChatGPT) como apoyo complementario para la generación de sinónimos y la estructuración de combinaciones booleanas. No obstante, el

proceso se mantuvo bajo supervisión humana en todo momento, evitando la automatización total y garantizando la pertinencia, precisión y validez científica de los términos seleccionados.

Basándose en estudios previos que validan el uso de IA en revisiones sistemáticas [13], se definió una base terminológica sólida y bien fundamentada. Los términos clave seleccionados fueron: Composite, Mechanical y Prediction. Estos se eligieron por su capacidad para abarcar de manera amplia y precisa los estudios relacionados con materiales compuestos, sus propiedades mecánicas y los modelos empleados para su predicción.

Para la recolección de información científica, se seleccionó la base de datos Scopus como fuente principal, debido a su reconocido prestigio, amplio alcance en publicaciones indexadas y alta pertinencia en las áreas de ingeniería, ciencia de materiales y tecnología.

Esta plataforma ofreció acceso completo mediante las credenciales institucionales del autor, lo que permitió una búsqueda sistemática, amplia y confiable de literatura especializada. Aunque existen herramientas orientadas a minería de datos avanzada, este estudio optó por priorizar la trazabilidad y la replicabilidad metodológica, aplicando directamente las cadenas de búsqueda optimizadas en las bases de datos primarias.

Se definieron dos estrategias de búsqueda, estructuradas a partir de los términos clave previamente establecidos. La primera estrategia "Composite" AND "Mechanical" tuvo como objetivo identificar investigaciones centradas en la caracterización de propiedades mecánicas de materiales compuestos, tales como resistencia, rigidez y dureza. La segunda estrategia "Composite" AND "Mechanical" AND "Prediction" estuvo orientada a localizar estudios enfocados en metodologías de predicción. Estas combinaciones permitieron focalizar la revisión en los aspectos técnicos fundamentales del objeto de estudio.

Con el fin de asegurar la calidad, actualidad y pertinencia de los estudios seleccionados, se aplicaron los criterios de inclusión definidos en la metodología. La aplicación de estos filtros permitió reducir significativamente el número inicial de resultados, concentrando el análisis en estudios con mayor relevancia y valor técnico para el estudio.

La estrategia de búsqueda "Composite" AND "Mechanical" permitió identificar un total de 24.597 artículos, lo que evidencia un volumen considerable

de estudios enfocados en la caracterización de las propiedades mecánicas de los materiales compuestos. Si bien este resultado era previsible, pone de manifiesto la relevancia de estas investigaciones, ya que comprender el comportamiento de los compuestos frente a cargas externas es fundamental para garantizar su fiabilidad, durabilidad y desempeño en aplicaciones estructurales, industriales y tecnológicas.

El análisis de la evolución temporal de las publicaciones relacionadas con la caracterización mecánica de materiales compuestos, presentado en la Figura 3, evidencia un crecimiento significativo en la producción científica entre los años 2020 y 2023. Posteriormente, se observa una estabilización en la cantidad de artículos hacia el 2024. Este comportamiento refleja un interés que, tras un rápido ascenso, ha logrado consolidarse, ratificando a esta línea de investigación como un componente fundamental en el desarrollo de nuevos materiales dentro del campo de la ingeniería y la innovación tecnológica.




Figura 3: Evolución temporal de publicaciones científicas con las palabras clave 'Mechanical' y 'Composite'

la Figura 4 muestra la distribución geográfica de la producción científica en el área, destacando a China, Estados Unidos e India como los países con mayor número de publicaciones relacionadas con materiales compuestos y sus propiedades mecánicas. Este volumen de producción científica es consistente con la elevada demanda de materiales compuestos en estas regiones para sectores estratégicos como la aeronáutica, la automoción, la construcción y las energías

renovables, lo cual ha incentivado la generación de conocimiento técnico especializado [14].




Figura 4: Distribución por país de publicaciones científicas sobre estudios en propiedades mecánicas en materiales compuestos

La búsqueda realizada con la estrategia “Composite” AND “Mechanical” AND “Prediction” arrojó 3.028 resultados, lo que representa una disminución sustancial en comparación con la búsqueda anterior que no incluía el término “Prediction”. Esta reducción se debe a que el enfoque predictivo añade un nivel adicional de especialización, lo cual restringe el espectro general de estudios disponibles. No obstante, la inclusión de este término permitió enfocar la búsqueda en investigaciones que incorporan modelos y herramientas analíticas orientadas a la estimación de propiedades mecánicas, aportando así un valor diferencial al análisis.

A pesar del menor volumen global de resultados, el comportamiento temporal de las publicaciones, representado en la Figura 5, muestra una tendencia creciente en los últimos años. Este aumento refleja el creciente interés de la comunidad científica por incorporar métodos predictivos en el estudio de materiales compuestos. Dicha tendencia es consistente con la literatura reciente, la cual destaca una mayor adopción de herramientas computacionales y de inteligencia artificial debido a su capacidad para modelar comportamientos complejos con mayor eficiencia que los métodos tradicionales [7].




Figura 5: Evolución temporal de publicaciones científicas con las palabras clave 'Mechanical', 'Composite' y 'Prediction'

La Figura 6 reafirma el liderazgo de China y Estados Unidos como los principales países productores de conocimiento en el ámbito de la predicción de propiedades mecánicas en materiales compuestos. Su protagonismo ha impulsado el desarrollo de enfoques predictivos cada vez más avanzados, consolidándolos como referentes globales en la aplicación de modelos computacionales y técnicas de simulación para el diseño y análisis de estos materiales.




Figura 6: Distribución por país de publicaciones científicas sobre predicción de propiedades mecánicas en materiales compuestos

B. Identificación y Clasificación de Metodologías

A partir de la revisión bibliográfica realizada, se constató que la predicción de las propiedades mecánicas de los materiales compuestos constituye un desafío técnico considerable, debido a la naturaleza heterogénea y anisotrópica de estos

materiales [15]. Esta complejidad ha dado lugar al desarrollo de múltiples enfoques metodológicos, cada uno orientado a capturar distintos aspectos del comportamiento mecánico de los compuestos. Mediante la aplicación rigurosa de los criterios de selección y una revisión crítica de los resultados obtenidos en Scopus, se delimitó un número de 61 estudios idóneos para el análisis por su calidad metodológica y relevancia temática. De manera general, las metodologías identificadas pueden agruparse en cuatro categorías principales: modelos analíticos, simulaciones numéricas con métodos de elementos finitos, técnicas de inteligencia artificial y pruebas experimentales.

- Modelos analíticos:

Los enfoques tradicionales para predecir las propiedades mecánicas de los materiales compuestos suelen basarse en modelos analíticos que tienen en cuenta las propiedades de los componentes individuales y sus interacciones [16]. Por ejemplo, la regla de las mezclas y otros modelos micromecánicos como el de Chamis, Halpin Tsai y Nielson se han utilizado ampliamente para estimar las propiedades efectivas de los compuestos basándose en las fracciones de volumen y las propiedades mecánicas de las fibras y la matriz [17].

Sin embargo, estas aproximaciones, que establecen límites teóricos para propiedades como el módulo de Young, se sustentan en supuestos ideales: deformación y esfuerzo uniformes. Tales condiciones simplifican en exceso el comportamiento real, ignorando la heterogeneidad microestructural y la interacción compleja entre fases. Como resultado, su aplicabilidad se restringe a escenarios idealizados, ofreciendo predicciones aproximadas más que representaciones precisas del comportamiento del material [18].

Modelos más sofisticados basados en micromecánica, como el método de Eshelby para inclusiones equivalentes y su extensión al modelo de Mori-Tanaka, representan un avance significativo [18]. Estos métodos consideran el campo de tensión perturbado generado por las inclusiones (fibras) dentro de una matriz infinita, permitiendo estimar tensores de rigidez elástica mediante el uso del tensor de concentración de deformación. Este enfoque aborda la interacción entre fase y matriz de forma más rigurosa que los modelos puramente empíricos o semiempíricos, incorporando aspectos geométricos y mecánicos de las inclusiones, como

su forma, orientación y concentración volumétrica [19].

A pesar de los avances logrados, los modelos analíticos presentan una limitación fundamental, su incapacidad para representar fenómenos localizados, como las concentraciones de esfuerzos en interfaces, la formación de microgrietas y la influencia de una microestructura aleatoria [20]. En consecuencia, su aplicación se restringe principalmente a la estimación de propiedades elásticas globales bajo condiciones de carga simples.

- Elementos finitos:

El análisis de elementos finitos es un método numérico prevalente utilizado para predecir el comportamiento mecánico de los materiales compuestos bajo diversas condiciones de carga. Las simulaciones permiten el modelado detallado de la microestructura del material compuesto, incluida la disposición de las fibras y las propiedades de la matriz [21]. Este método permite reproducir los efectos de geometrías complejas y escenarios de carga, lo que lo hace muy valioso para aplicaciones de ingeniería.

Además, se han desarrollado técnicas de modelado mesomecánico para analizar las características mecánicas de los materiales compuestos tejidos y textiles, considerando los hilos como estructuras homogéneas [22]. Estos enfoques permiten vincular la arquitectura interna del material con su respuesta mecánica global, integrando las interacciones locales en el análisis del componente final.

Sin embargo, la aplicación rigurosa del Método de Elementos Finitos a materiales compuestos exige una profundización en las metodologías constitutivas. La capacidad de modelar la microestructura se ejecuta mediante la Micromecánica Computacional, que emplea el MEF para analizar un Elemento de Volumen Representativo (RVE) bajo condiciones de frontera periódicas. Este enfoque es fundamental para el proceso de homogeneización, ya que permite determinar las propiedades mecánicas efectivas macroscópicas y anisotrópicas [23].

Para la predicción precisa del comportamiento no lineal y el fallo, las simulaciones por MEF deben integrar modelos constitutivos avanzados. Estos incluyen los Modelos de Daño Progresivo Continuo

(CDM), que utilizan variables internas para degradar la rigidez de la fibra o la matriz a medida que se acumula el daño [24]. También se emplean los Modelos de Zona Cohesiva (CZM), los cuales son críticos para simular la delaminación en laminados al definir la relación tensión-apertura en las interfaces interlaminares y permitir la predicción de la iniciación y propagación de grietas. En este contexto, la implementación de las leyes de tracción-separación entre la fibra y la matriz es crucial para modelar la separación a microescala, promoviendo la delaminación en la respuesta estructural del material homogenizado [25].

Es imperativo reconocer los desafíos técnicos del método. El modelado de RVEs con el detalle necesario para la interfaz fibra-matriz resulta en un alto coste computacional. Para abordar esto, las estrategias de vanguardia en ingeniería computacional incluyen el uso de técnicas multiescala, donde las propiedades microestructurales se calculan y se utilizan solo en las regiones del modelo macroscópico que experimentan altos gradientes de tensión, optimizando significativamente los recursos computacionales [23]. Esta aproximación es especialmente relevante en el análisis de estructuras sometidas a cargas extremas, como explosiones, donde la captura precisa de fenómenos de perforación sigue siendo un reto importante [24].

- Técnicas de inteligencia artificial:

En los últimos años, el aprendizaje automático ha surgido como una poderosa herramienta para predecir las propiedades mecánicas de los materiales compuestos. Se han empleado técnicas como las redes neuronales artificiales y el aprendizaje profundo para analizar grandes conjuntos de datos e identificar patrones que se correlacionan con el rendimiento mecánico [26].

Estos métodos pueden manejar las complejidades de las microestructuras de materiales compuestos y han demostrado ser prometedores para mejorar la precisión de la predicción en comparación con los modelos tradicionales. Por ejemplo, se han utilizado algoritmos de aprendizaje automático para predecir las propiedades de los nanocompuestos, en los que las interacciones a nanoescala influyen significativamente en el comportamiento mecánico global [27]. La integración del aprendizaje automático con los enfoques de modelado tradicionales está allanando el camino para la

creación de marcos de predicción más robustos que puedan adaptarse a nuevos materiales y configuraciones.

En complemento a las técnicas generales descritas, la literatura reciente ha incorporado algoritmos de inteligencia artificial (IA) que mejoran significativamente la predicción de propiedades en materiales compuestos. Modelos supervisados como Random Forest y XGBoost son particularmente efectivos para predecir propiedades mecánicas (módulo de elasticidad, resistencia) a partir de datos experimentales limitados o con alta variabilidad, superando en estabilidad a las redes neuronales tradicionales en estos escenarios [26].

Para datos de imagen, las Redes Neuronales Convolucionales (CNN) han demostrado un rendimiento excepcional. Pueden predecir directamente campos de esfuerzo y deformación a partir de micrografías (SEM, tomografía) sin necesidad de modelado físico explícito. Por ejemplo, una CNN entrenada con imágenes segmentadas de microestructuras de polímeros reforzados logró predecir el campo de esfuerzos con una precisión del 99% respecto a simulaciones FEM, reduciendo el tiempo de cálculo de 92.5 horas a segundos [28]. Esta capacidad permite identificar zonas de alto esfuerzo, potenciales puntos de fallo o daño incipiente, directamente desde la imagen de la microestructura.

Modelos más recientes, como las Redes Neuronales de Grafos (GNN), modelan la microestructura como un grafo capturando con mayor fidelidad la relación entre la arquitectura interna y la respuesta mecánica global [29].

A pesar de sus ventajas, estos enfoques enfrentan desafíos críticos. La calidad y cantidad de datos siguen siendo el cuello de botella: conjuntos pequeños, ruido experimental y falta de estandarización llevan fácilmente a sobreajuste. La interpretabilidad también es una limitación importante, muchos modelos siguen siendo "cajas negras", dificultando la comprensión física de las relaciones aprendidas [30].

- Pruebas experimentales:

La predicción de las propiedades mecánicas de los materiales compuestos a partir de pruebas experimentales es un proceso integral que combina observaciones empíricas con fundamentos teóricos.

En estos materiales, el comportamiento mecánico está condicionado por múltiples variables, entre ellas la naturaleza de los refuerzos (como fibras naturales o sintéticas), la matriz (polimérica, metálicas o cerámica), la calidad de la interfaz fibra-matriz, las técnicas de procesamiento empleadas y las condiciones de carga a las que serán sometidos [31].

Uno de los objetivos centrales de esta evaluación es establecer relaciones cuantificables entre la microestructura interna del compuesto y su respuesta mecánica global. Para ello, se recurre a ensayos estandarizados como tracción, compresión, flexión o impacto, los cuales permiten caracterizar propiedades clave como el módulo de elasticidad, la resistencia última, la deformación a ruptura y la tenacidad [32].

Estos ensayos no solo permiten comparar composiciones o métodos de fabricación, sino que también sirven como base para alimentar modelos predictivos y validar simulaciones numéricas. La información obtenida es crucial para optimizar el diseño de compuestos y garantizar su desempeño en aplicaciones estructurales exigentes [33].

C. Análisis de beneficios y limitaciones

A continuación, se relacionan los beneficios y limitaciones de cada una de las metodologías utilizadas para la predicción de propiedades de los materiales compuestos

- Pruebas experimentales:

Una de las principales ventajas de las pruebas experimentales es la obtención de datos empíricos confiables, ya que permiten medir directamente propiedades como la resistencia a la tracción, proporcionando datos esenciales para aplicaciones industriales. Además, los datos experimentales son fundamentales para la validación de modelos analíticos, aumentando la confiabilidad de las predicciones sobre el comportamiento de los materiales. Esta validación también se extiende a modelos computacionales y simulaciones, lo que garantiza que reflejen con precisión el comportamiento de los materiales reales y mejora la eficiencia en el diseño de nuevos compuestos [34].

Otra ventaja significativa es la posibilidad de explorar nuevas formulaciones, como combinaciones innovadoras de refuerzos híbridos

(vidrio-carbono), optimizando las propiedades de los materiales [35]. Asimismo, estas pruebas permiten estudiar parámetros específicos, como la orientación de las fibras, la composición de la matriz y las condiciones ambientales, para comprender su influencia en el rendimiento mecánico [36]. adicionalmente, los ensayos experimentales facilitan la identificación de mecanismos de falla, proporcionando información crucial para aplicaciones de alta seguridad en la ingeniería aeroespacial, automotriz y civil [37].

Por otro lado, estas pruebas presentan desventajas significativas. Una de las principales es el alto costo asociado con los equipos especializados, el personal capacitado y los protocolos de prueba extensivos, lo que representa un reto económico, especialmente en proyectos con recursos limitados [38]. Además, la variabilidad inherente en los materiales, debido al proceso de fabricación y las condiciones ambientales, puede dificultar la interpretación de los resultados y la generalización de los hallazgos [39].

Otra limitación es que las pruebas de laboratorio no siempre logran simular las complejas condiciones operativas, como cambios de temperatura, absorción de humedad y cargas de fatiga, lo que puede reducir la aplicabilidad de los resultados [40].

Además, la incorporación de partículas o nanopartículas en una matriz polimérica representa un desafío significativo debido a las marcadas diferencias en las propiedades fisicoquímicas entre ambas fases como la polaridad, la energía de superficie y la compatibilidad interfacial lo que favorece la aglomeración, dificulta la transferencia eficaz de carga y debilita la adherencia en la interfaz, comprometiendo así la homogeneidad del compuesto y reduciendo la eficacia del refuerzo [41].

Esta incompatibilidad se agrava por la necesidad de tratamientos superficiales precisos, condiciones de dispersión controladas y un estricto seguimiento de parámetros de procesamiento como la temperatura, el tiempo de mezcla y la velocidad de agitación, lo que incrementa considerablemente la complejidad técnica, el tiempo de desarrollo y los costos de producción, limitando la escalabilidad de estos materiales en aplicaciones industriales [42].

La necesidad de realizar múltiples tipos de ensayos, como tracción, compresión y corte, para obtener una

visión completa de las propiedades mecánicas también incrementa los costos y el tiempo necesario [43]. Además, los efectos de escala en los ensayos pueden generar discrepancias, ya que las pruebas en especímenes pequeños no siempre representan el comportamiento de componentes o estructuras más grandes [44].

- Modelos analíticos:

Los modelos analíticos ofrecen una herramienta eficiente para predecir propiedades mecánicas de materiales compuestos, gracias a su simplicidad matemática y bajo requerimiento computacional. Permiten estimar parámetros como los módulos de elasticidad (longitudinal y transversal), módulos de corte y coeficientes de Poisson de forma rápida, reduciendo significativamente la dependencia de ensayos experimentales y simulaciones avanzadas [45], [46].

Una de sus principales fortalezas es la optimización de recursos, tanto en tiempo como en costos. Al disminuir la necesidad de pruebas físicas prolongadas y cálculos complejos, estos modelos agilizan el diseño y desarrollo de nuevos materiales, lo que se traduce en procesos más económicos y eficientes [47].

Asimismo, destacan por su capacidad predictiva. Al incorporar variables microestructurales como el contenido y orientación de fibras, o la presencia de defectos, permiten anticipar el comportamiento del material compuesto antes de su fabricación. Modelos como el de Halpin-Tsai ejemplifican este enfoque al facilitar la optimización de propiedades como la durabilidad y la vida útil [48].

Su versatilidad y facilidad de implementación amplían su aplicabilidad en múltiples sectores, desde la ingeniería civil hasta el desarrollo de compuestos híbridos sostenibles. Su formulación simple permite una integración directa en herramientas computacionales y los convierte en un complemento valioso para simulaciones por elementos finitos durante las fases iniciales del diseño [18].

Sin embargo, los modelos micromecánicos analíticos presentan diversas limitaciones. Una de las principales es su dependencia de suposiciones simplificadoras, como la homogeneidad, isotropía, elasticidad lineal, geometrías idealizadas y una perfecta adherencia entre la matriz y el refuerzo, las

cuales no siempre representan adecuadamente la complejidad de los materiales compuestos reales [2].

Otra limitación importante es su aplicabilidad restringida a configuraciones específicas, como refuerzos unidireccionales o distribuciones regulares de fibras. Estos modelos no son adecuados para arquitecturas complejas, como tejidos tridimensionales o compuestos trenzados, lo que limita su utilidad en diseños más avanzados [49].

Además, la precisión de sus predicciones depende en gran medida de la calidad de los parámetros de entrada, como propiedades mecánicas de los componentes, fracciones volumétricas y geometrías internas. Estos parámetros son altamente sensibles a las variaciones microestructurales, lo que puede generar discrepancias significativas entre el modelo y el comportamiento real del material [50].

Estos modelos suelen omitir los efectos ambientales, como la temperatura y la humedad, lo que compromete su precisión en condiciones de servicio variables. Además, aunque se basan en formulaciones teóricas, requieren validación experimental para garantizar su confiabilidad, lo cual implica inversiones adicionales en tiempo y recursos [51].

- Elementos finitos:

Una de las principales ventajas del FEM es su capacidad para modelar geometrías complejas y materiales heterogéneos. Este método permite discretizar estructuras compuestas en elementos finitos, representando diferentes fases del material y sus interacciones. Además, el FEM tiene la capacidad de analizar escenarios tanto estáticos como dinámicos, lo que permite explorar mecanismos de daño en la matriz y las fibras de compuestos bajo diversas condiciones de carga [52].

Otra ventaja importante es la incorporación de modelos avanzados de materiales. El FEM permite modelar comportamientos únicos, como anisotropía y viscoelasticidad, que son esenciales para caracterizar materiales compuestos [53]. Asimismo, ofrece una mayor precisión en comparación con los métodos analíticos tradicionales, que a menudo simplifican en exceso el comportamiento de los materiales. El FEM proporciona un nivel de detalle

superior para reflejar la realidad de los compuestos [54].

El FEM también destaca por su capacidad para realizar estudios paramétricos y optimizar diseños. Permite variar parámetros de diseño, como la orientación de las fibras, la secuencia de apilamiento y las propiedades materiales, con el fin de identificar configuraciones óptimas que ofrezcan un rendimiento mecánico deseado [55].

Sin embargo, el FEM presenta también desventajas importantes. Una de ellas es la complejidad en la creación de modelos. El proceso de mallado puede ser laborioso y requiere precisión para representar adecuadamente la geometría y las propiedades del material. Los materiales compuestos, al ser heterogéneos y contener múltiples fases con propiedades mecánicas distintas, exigen modelos detallados que aumentan significativamente los costos computacionales y el tiempo requerido [15].

Otra limitación significativa son las altas demandas computacionales. La discretización completa de todas las fases de un compuesto puede generar un alto número de elementos finitos, incrementando la complejidad y los tiempos de simulación. La generación de mallas detalladas para modelos a gran escala o geometrías complejas puede ser intensiva en tiempo y recursos computacionales, lo que limita su aplicabilidad en ciertas industrias [56].

El FEM también depende de la calidad de los datos de entrada. La precisión del método está estrechamente vinculada a la calidad de las propiedades del material y las condiciones de contorno, que pueden ser difíciles de obtener en compuestos heterogéneos. Además, los errores numéricos asociados al tamaño de la malla y al tipo de elemento pueden afectar la convergencia y la estabilidad de las soluciones [57].

Las simulaciones FEM requieren validación experimental para garantizar la precisión y evitar interpretaciones erróneas. Esto implica complementar el trabajo computacional con datos experimentales, lo que añade tiempo y esfuerzo al proceso [58].

- Técnicas de inteligencia artificial:

Una de las principales ventajas de la IA es su capacidad para analizar grandes volúmenes de datos y detectar patrones complejos. Por ejemplo, el

aprendizaje automático permite identificar relaciones en conjuntos de datos masivos que son difíciles de detectar con métodos tradicionales, facilitando el diseño de materiales con propiedades específicas superiores [59].

Otra ventaja es la reducción de costos y tiempo en pruebas experimentales, ya que la IA puede utilizar datos existentes para realizar predicciones, acelerando significativamente el desarrollo de nuevos materiales [26].

La inteligencia artificial destaca por su adaptabilidad a nuevos materiales y condiciones, una ventaja clave en el dinámico campo de los materiales compuestos. Además, los algoritmos de aprendizaje automático mejoran continuamente sus predicciones al aprender de los datos, descubriendo relaciones ocultas entre estructura y propiedades [27].

A pesar de sus ventajas, la inteligencia artificial enfrenta desafíos importantes, como la necesidad de datos de alta calidad. La falta de datos representativos puede generar predicciones erróneas, y el uso de conjuntos pequeños aumenta el riesgo de sobreajuste, afectando su capacidad de generalización [60], [61].

Otra desventaja, especialmente en el caso del aprendizaje profundo, es su limitada interpretabilidad, lo que dificulta comprender cómo se generan las predicciones y restringe su uso en contextos críticos. Asimismo, su desempeño es altamente sensible a la elección del algoritmo y de los hiperparámetros, cuyo ajuste puede requerir un alto costo computacional y afectar significativamente los resultados [62].

Factor	Experimental	Modelos Analíticos	Elementos Finitos	IA (ML/DL)
Precisión	Alta (datos empíricos confiables, pero depende de la calidad del ensayo)	Moderada (dependiente de simplificaciones y suposiciones)	Alta (si se refina la malla y se usan datos precisos)	Alta (depende de calidad y cantidad de datos de entrenamiento)
Costo	Alto (equipos especializados y personal capacitado)	Bajo (costo computacional y recursos teóricos)	Moderado-Alto (software y tiempo computacional)	Moderado-Alto (recursos computacionales y de datos)
Tiempo	Largo (ensayos físicos requieren tiempo significativo)	Rápido (si las ecuaciones están definidas)	Moderado (depende de la complejidad del modelo)	Moderado (entrenamiento de modelos puede ser intensivo)
Flexibilidad	Baja (ensayos limitados a muestras específicas)	Baja (limitado a configuraciones simples y regulares)	Moderada (puede ajustarse a diferentes escenarios)	Alta (adaptable a múltiples condiciones y materiales)
Requerimientos Técnicos	Alto (experiencia en laboratorio y protocolos estrictos)	Moderado (conocimiento matemático/analítico requerido)	Alto (dominio de software especializado como FEM requerido)	Alto (conocimiento en IA, programación y datos necesario)
Repetibilidad	Moderada (variabilidad en materiales afecta resultados)	Alta (si los parámetros y ecuaciones son consistentes)	Alta (resultados consistentes con modelos bien definidos)	Alta (si el modelo está entrenado con datos representativos)
Capacidad Predictiva	Moderada (limitado a las configuraciones probadas)	Moderada (basada en ecuaciones predefinidas)	Alta (permite explorar configuraciones no experimentadas)	Muy Alta (descubre patrones complejos en grandes datos)

Tabla 1: Comparación de las metodologías

Integrar la inteligencia artificial con metodologías tradicionales es un desafío porque combina enfoques empíricos con modelos basados en principios físicos. Por ejemplo, fusionar simulaciones de dinámica molecular con IA exige un conocimiento profundo de ambas técnicas [27]. Además, aunque la IA puede modelar relaciones complejas entre composición y propiedad, suele fallar al captar relaciones sistemáticas entre estructura y propiedad, fundamentales para predecir el comportamiento de los materiales [63].

Los altos costos computacionales del entrenamiento de modelos de aprendizaje profundo son una barrera importante, especialmente para arquitecturas complejas que requieren recursos de alto rendimiento, lo que puede limitar su adopción [64].

En la tabla 1 se presenta una comparación de factores clave, como precisión, costo, tiempo, flexibilidad, requerimientos técnicos, repetibilidad y capacidad predictiva, entre los métodos experimental, modelos analíticos, elementos finitos e inteligencia artificial (IA).

Los valores asignados en la Tabla 1 se fundamentan en el análisis crítico de la literatura revisada y en las características inherentes a cada enfoque. Por ejemplo, la alta precisión atribuida a los métodos experimentales se justifica por su capacidad de

medir directamente el comportamiento real del material bajo condiciones controladas, tal como se observa en ensayos estandarizados de tracción o flexión [32]. En contraste, la precisión moderada de los modelos analíticos deriva de sus supuestos simplificadores, como la perfecta adherencia fibra-matriz o la distribución uniforme de refuerzos, lo cual puede desviarse significativamente del

comportamiento real en compuestos con arquitecturas complejas [10].

De manera similar, el alto costo de los métodos experimentales refleja no solo el gasto en equipos especializados y personal capacitado [35], sino también el tiempo requerido para fabricar múltiples muestras y realizar diferentes tipos de ensayos [49]. Por otro lado, los modelos analíticos obtienen una calificación de bajo costo debido a su naturaleza computacionalmente ligera y su implementación en cálculos manuales o hojas de cálculo simples, lo que los hace accesibles incluso con recursos limitados.

En cuanto a la capacidad predictiva, la inteligencia artificial recibe una valoración de "Muy Alta" porque algoritmos como las Redes Neuronales Convolucionales (CNN) han demostrado predecir campos de esfuerzo directamente desde micrografías con precisión superior al 99 % respecto a simulaciones por elementos finitos [28]. Este tipo de avance ilustra el potencial transformador de la IA

en escenarios donde se dispone de datos representativos.

Cabe destacar que, la flexibilidad alta de las técnicas de IA se sustenta en su capacidad para adaptarse a nuevas configuraciones de materiales sin necesidad de reformulaciones teóricas completas, simplemente mediante reentrenamiento con nuevos datos [62]. Esta característica contrasta con los modelos analíticos, cuya aplicabilidad está restringida a geometrías y condiciones específicas [51].

D. Perspectivas futuras

El análisis comparativo de metodologías para predecir propiedades mecánicas en compuestos revela una transición hacia un ecosistema predictivo integrado, donde los enfoques físicos y de inteligencia artificial ya no se oponen, sino que se refuerzan mutuamente [65], [66].

La simulación por elementos finitos se está acelerando mediante modelos sustitutos guiados por principios físicos, mientras que redes convolucionales y de grafos extraen comportamiento mecánico directamente de imágenes microestructurales, eliminando la necesidad de modelado explícito. Esta convergencia entre visión artificial y mecánica de medios continuos redefine la predicción: ya no es una extrapolación teórica, sino una interpretación inteligente de la realidad material.

Sin embargo, persisten barreras críticas. La escasez de datos estandarizados, representativos y bien documentados limita la generalización y favorece el sobreajuste. Además, la opacidad de los modelos de aprendizaje profundo genera desconfianza en entornos industriales, donde se exige trazabilidad mecanicista. La mayoría de estos modelos ignoran condiciones reales de servicio reduciendo su aplicabilidad práctica.

Las rutas más prometedoras apuntan a marcos híbridos: integrar la solidez de los modelos físicos con la adaptabilidad de la IA, sin sacrificar los principios fundamentales. Es urgente desarrollar bases de datos abiertas que incluyan propiedades mecánicas, parámetros de procesamiento, tratamientos superficiales y condiciones ambientales.

Paralelamente, se necesita inteligencia artificial explicable, capaz de vincular predicciones con mecanismos observables para convertir predicciones eficientes en decisiones de diseño confiables, seguras y sostenibles.

IV. CONCLUSIONES

El estudio reveló que las metodologías para la predicción de propiedades mecánicas de materiales compuestos se agrupan principalmente en enfoques experimentales, analíticos, numéricos (FEM) y de inteligencia artificial, cada uno con sus ventajas y limitaciones, pero a menudo complementarios entre sí.

El análisis comparativo de estas metodologías permitió identificar sus fortalezas y desafíos. Las pruebas experimentales destacan por su alta precisión y fiabilidad, aunque presentan limitaciones en términos de costos, tiempo y replicabilidad en condiciones reales. Los modelos analíticos, por su parte, ofrecen rapidez y simplicidad, pero su aplicabilidad está restringida por las simplificaciones que asumen en su formulación.

El método de elementos finitos (FEM) sobresale como una herramienta poderosa para modelar configuraciones complejas, aunque requiere recursos computacionales significativos y validación experimental. En contraste, las técnicas de inteligencia artificial, como el aprendizaje automático y profundo, muestran un gran potencial para manejar datos complejos y reducir costos experimentales. Sin embargo, estas técnicas enfrentan desafíos relacionados con la calidad de los datos y la interpretabilidad de los modelos.

Este estudio subraya la importancia de integrar enfoques complementarios para enfrentar la complejidad inherente a los materiales compuestos. Una combinación estratégica de métodos experimentales, analíticos, FEM y técnicas de inteligencia artificial puede generar predicciones más precisas y robustas, optimizando el diseño y desarrollo de estos materiales. La selección del método más adecuado dependerá del contexto de aplicación y de los recursos disponibles.

V. REFERENCIAS

- [1] V. S. Hiremath, D. M. Reddy, R. Reddy Mutra, A. Sanjeev, T. Dhilipkumar, y N. J, «Thermal degradation and fire retardant behaviour of natural

- fibre reinforced polymeric composites- A comprehensive review», *J. Mater. Res. Technol.*, vol. 30, pp. 4053-4063, may 2024, doi: 10.1016/j.jmrt.2024.04.085.
- [2] Y. Wang y Z. Huang, «A Review of Analytical Micromechanics Models on Composite Elastoplastic Behaviour», *Procedia Eng.*, vol. 173, pp. 1283-1290, 2017, doi: 10.1016/j.proeng.2016.12.159.
- [3] G. Qin, Q. Fan, P. Mi, M. Li, W. Mu, y J. Na, «Review of aging mechanisms, mechanical properties, and prediction models of fiber-reinforced composites in natural environments», *Polym. Compos.*, vol. 45, n.º 16, pp. 14448-14474, 2024, doi: 10.1002/pc.28799.
- [4] R. Phiri, S. Mavinkere Rangappa, S. Siengchin, O. P. Oladijo, y T. Ozbakkaloglu, «Advances in lightweight composite structures and manufacturing technologies: A comprehensive review», *Heliyon*, vol. 10, n.º 21, p. e39661, nov. 2024, doi: 10.1016/j.heliyon.2024.e39661.
- [5] D. D. Oloju, G. O. Okagbare, y S. O. Ikri, «A Review on the Industrial Applications and Properties of Fiber-Reinforced and Other Polymeric Composites», *NIPES - J. Sci. Technol. Res.*, vol. 4, n.º 2, jun. 2022, doi: 10.37933/nipes/4.2.2022.15.
- [6] P.-H. Lai, E. D. Gomez, B. D. Vogt, y W. F. Reinhart, «Predicting the Strength of Composites with Computer Vision Using Small Experimental Datasets», *ACS Mater. Lett.*, vol. 7, n.º 4, pp. 1503-1511, abr. 2025, doi: 10.1021/acsmaterialslett.4c02424.
- [7] M. Karuppusamy, R. Thirumalaisamy, S. Palanisamy, S. Nagamalai, E. El Sayed Massoud, y N. Ayrlimis, «A review of machine learning applications in polymer composites: advancements, challenges, and future prospects», *J. Mater. Chem. A*, vol. 13, n.º 22, pp. 16290-16308, 2025, doi: 10.1039/D5TA00982K.
- [8] H. Alotaibi, C. Soutis, y M. Jabbari, «FEM and FVM Methods for Design and Manufacturing of Hierarchical Aerospace Composites: A Review», *Appl. Sci.*, vol. 15, n.º 16, p. 8896, ago. 2025, doi: 10.3390/app15168896.
- [9] M. Y. Salim *et al.*, «Natural fibre-reinforced thermoplastic composites: A bibliometric analysis and review of eco-friendly solutions in exterior automotive components», *J. Mater. Res. Technol.*, vol. 39, pp. 6755-6774, nov. 2025, doi: 10.1016/j.jmrt.2025.10.230.
- [10] B. Raju, S. R. Hiremath, y D. Roy Mahapatra, «A review of micromechanics based models for effective elastic properties of reinforced polymer matrix composites», *Compos. Struct.*, vol. 204, pp. 607-619, nov. 2018, doi: 10.1016/j.compstruct.2018.07.125.
- [11] V. Panwar, P. Gupta, A. K. Bagha, y N. Chauhan, «A Review on studies of Finite Element Model Updating and Updating of Composite Materials», *Mater. Today Proc.*, vol. 5, n.º 14, pp. 27912-27918, 2018, doi: 10.1016/j.matpr.2018.10.030.
- [12] S. S. Sorour, C. A. Saleh, y M. Shazly, «A review on machine learning implementation for predicting and optimizing the mechanical behaviour of laminated fiber-reinforced polymer composites», *Heliyon*, vol. 10, n.º 13, p. e33681, jul. 2024, doi: 10.1016/j.heliyon.2024.e33681.
- [13] A. C. Picalho, G. R. D. Oliveira, y A. S. Cativelli, «Inteligência artificial no levantamento bibliográfico em bases de dados científicos: comparando expressões de busca no ChatGPT, Copilot e Gemini», *RDBCI Rev. Digit. Bibl. E Ciênc. Informação*, vol. 23, p. e025013, feb. 2025, doi: 10.20396/rdbci.v23i00.8678378.
- [14] C. Veres y M. Tănase, «A Bibliometric and Systematic Review of the Use of Recycled Composite Materials with an Emphasis on the Mechanical Performance of Structures», *Materials*, vol. 18, n.º 3, p. 607, ene. 2025, doi: 10.3390/ma18030607.
- [15] D. E. S. Rodrigues, J. Belinha, F. M. A. Pires, L. M. J. S. Dinis, y R. M. N. Jorge, «Homogenization technique for heterogeneous composite materials using meshless methods», *Eng. Anal. Bound. Elem.*, vol. 92, pp. 73-89, jul. 2018, doi: 10.1016/j.enganabound.2017.12.012.
- [16] A. Jasti, B. Akhil Chandra, y S. Biswas, «Modified Halpin-Tsai model for predicting the mechanical properties of polymer composites reinforced with different cross-sectional fibers», *Mater. Today Proc.*, vol. 91, pp. 14-18, 2023, doi: 10.1016/j.matpr.2023.04.131.
- [17] Y. Wang y Z. Huang, «Analytical Micromechanics Models for Elastoplastic Behavior of Long Fibrous Composites: A Critical Review and Comparative Study», *Materials*, vol. 11, n.º 10, p. 1919, oct. 2018, doi: 10.3390/ma11101919.
- [18] Y. C. Kim, H.-K. Jang, G. Joo, y J. H. Kim, «A Comparative Study of Micromechanical Analysis Models for Determining the Effective Properties of Out-of-Autoclave Carbon Fiber-Epoxy Composites», *Polymers*, vol. 16, n.º 8, p. 1094, abr. 2024, doi: 10.3390/polym16081094.
- [19] M. V. F. Machado, F. P. D. Lopes, N. T. Simonassi, E. A. D. Carvalho, y S. N. Monteiro, «Micromechanics for polymer matrix laminated composites: a literature review of fundamental

- models, advances and a trend analysis for future researches», *Obs. Econ. Latinoam.*, vol. 23, n.º 5, p. e10103, may 2025, doi: 10.55905/oelv23n5-182.
- [20] L. Wan, Y. Ismail, Y. Sheng, J. Ye, y D. Yang, «A review on micromechanical modelling of progressive failure in unidirectional fibre-reinforced composites», *Compos. Part C Open Access*, vol. 10, p. 100348, mar. 2023, doi: 10.1016/j.jcomc.2023.100348.
- [21] M. Kim y Y. Kim, «A Thermo-Mechanical Properties Evaluation of Multi-Directional Carbon/Carbon Composite Materials in Aerospace Applications», *Aerospace*, vol. 9, n.º 8, p. 461, ago. 2022, doi: 10.3390/aerospace9080461.
- [22] Y. Xie, G. Huang, H. Zhang, M. Xu, E. Sitnikova, y S. Li, «Efficient characterization of mechanical nonlinearity in triaxially braided composites by a novel unit cell», *Compos. Struct.*, vol. 366, p. 119234, ago. 2025, doi: 10.1016/j.compstruct.2025.119234.
- [23] N. K. Balasubramani, B. Zhang, N. T. Chowdhury, A. Mukkavilli, M. Suter, y G. M. Pearce, «Micro-mechanical analysis on random RVE size and shape in multiscale finite element modelling of unidirectional FRP composites», *Compos. Struct.*, vol. 282, p. 115081, feb. 2022, doi: 10.1016/j.compstruct.2021.115081.
- [24] Z. Guan, «Review of finite element modelling of composite structures subjected to extreme loading conditions», *Compos. Des. Manuf.*, vol. 1, n.º 1, p. wqaf005, jul. 2025, doi: 10.1093/cdm/wqaf005.
- [25] S. P. H. Skovsgaard y S. Heide-Jørgensen, «Three-dimensional mechanical behavior of composite with fibre-matrix delamination through homogenization of micro-structure», *Compos. Struct.*, vol. 275, p. 114418, nov. 2021, doi: 10.1016/j.compstruct.2021.114418.
- [26] F. Kibrete, T. Trzepieciński, H. S. Gebremedhen, y D. E. Woldemichael, «Artificial Intelligence in Predicting Mechanical Properties of Composite Materials», *J. Compos. Sci.*, vol. 7, n.º 9, p. 364, sep. 2023, doi: 10.3390/jcs7090364.
- [27] W. Jin, J. Pei, P. Xie, J. Chen, y H. Zhao, «Machine Learning-Based Prediction of Mechanical Properties and Performance of Nickel–Graphene Nanocomposites Using Molecular Dynamics Simulation Data», *ACS Appl. Nano Mater.*, vol. 6, n.º 13, pp. 12190-12199, 2023, doi: 10.1021/acsanm.3c01919.
- [28] Y. Sun, I. Hanhan, M. D. Sangid, y G. Lin, «Predicting Mechanical Properties from Microstructure Images in Fiber-reinforced Polymers using Convolutional Neural Networks», *J. Compos. Sci.*, vol. 8, n.º 10, p. 387, sep. 2024, doi: 10.3390/jcs8100387.
- [29] Y. Wang, K. Wang, y C. Zhang, «Applications of artificial intelligence/machine learning to high-performance composites», *Compos. Part B Eng.*, vol. 285, p. 111740, oct. 2024, doi: 10.1016/j.compositesb.2024.111740.
- [30] N. Franić, I. Pivac, y F. Barbir, «A review of machine learning applications in hydrogen electrochemical devices», *Int. J. Hydrog. Energy*, vol. 102, pp. 523-544, feb. 2025, doi: 10.1016/j.ijhydene.2025.01.070.
- [31] M. Chairi, J. El Bahaoui, I. Hanafi, F. Mata Cabrera, y G. Di Bella, «Composite Materials: A Review of Polymer and Metal Matrix Composites, Their Mechanical Characterization, and Mechanical Properties», en *Next Generation Fiber-Reinforced Composites - New Insights*, L. Li, A. B. Pereira, y A. L. Pereira, Eds., IntechOpen, 2023. doi: 10.5772/intechopen.106624.
- [32] I. Wadgave, S. Kulkarni, S. Katekar, y M. Kulkarni, «A comprehensive review on: Mechanical and acoustical characterization of natural fiber-reinforced composite», *Mater. Today Proc.*, p. S2214785324002979, may 2024, doi: 10.1016/j.matpr.2024.05.002.
- [33] J. Yun, S. Ryu, J. Kim, Y. Kim, y D.-W. Kim, «Equivalent modeling for the prediction of mechanical behaviors of composite sandwich structures with thick cell walls», *Compos. Struct.*, vol. 364, p. 119162, jul. 2025, doi: 10.1016/j.compstruct.2025.119162.
- [34] W. Mu, X. Chen, S. Li, Y. Sun, Q. Wang, y J. Na, «Mechanical Performances Analysis and Prediction of Short Plant Fiber-Reinforced PLA Composites», *Polymers*, vol. 15, n.º 15, p. 3222, jul. 2023, doi: 10.3390/polym15153222.
- [35] D. K. Rathore, R. K. Prusty, S. C. Mohanty, B. P. Singh, y B. C. Ray, «In-situ elevated temperature flexural and creep response of inter-ply glass/carbon hybrid FRP composites», *Mech. Mater.*, vol. 105, pp. 99-111, feb. 2017, doi: 10.1016/j.mechmat.2016.11.013.
- [36] H. Wu *et al.*, «Preparation of Bouligand biomimetic ceramic composites and the effect of different fiber orientations on mechanical properties», *J. Manuf. Process.*, vol. 132, pp. 789-801, dic. 2024, doi: 10.1016/j.jmapro.2024.11.031.
- [37] H. Zhang *et al.*, «Mechanical properties and failure mechanisms of three-dimensional stitched C/C-SiC ceramic matrix composites», *Ceram. Int.*, vol. 50, n.º 24, pp. 55487-55497, dic. 2024, doi: 10.1016/j.ceramint.2024.10.409.

- [38] X. Huang, S. Su, Z. Xu, Q. Miao, W. Li, y L. Wang, «Advanced Composite Materials for Structure Strengthening and Resilience Improvement», *Buildings*, vol. 13, n.º 10, p. 2406, sep. 2023, doi: 10.3390/buildings13102406.
- [39] M. Chen, X. Zhang, K. Shen, y G. Pan, «Uncertainty quantification and global sensitivity analysis for composite cylinder shell via data-driven polynomial chaos expansion», *J. Phys. Conf. Ser.*, vol. 2174, n.º 1, p. 012085, ene. 2022, doi: 10.1088/1742-6596/2174/1/012085.
- [40] M. Xu, B. Zeng, Z. An, X. Xiong, y X. Cheng, «Experimental and Numerical Investigation on Fatigue Properties of Carbon Fiber Cross-Ply Laminates in Hygrothermal Environments», *Polymers*, vol. 14, n.º 9, p. 1857, abr. 2022, doi: 10.3390/polym14091857.
- [41] A. B. Rashid, M. Haque, S. M. M. Islam, y K. M. R. Uddin Labib, «Nanotechnology-enhanced fiber-reinforced polymer composites: Recent advancements on processing techniques and applications», *Heliyon*, vol. 10, n.º 2, p. e24692, ene. 2024, doi: 10.1016/j.heliyon.2024.e24692.
- [42] A. A. Musa *et al.*, «Nano-Enhanced Polymer Composite Materials: A Review of Current Advancements and Challenges», *Polymers*, vol. 17, n.º 7, p. 893, mar. 2025, doi: 10.3390/polym17070893.
- [43] M. Lezgy-Nazargah, S. A. Emamian, E. Aghasizadeh, y M. Khani, «Predicting the mechanical properties of ordinary concrete and nano-silica concrete using micromechanical methods», *Sādhanā*, vol. 43, n.º 12, p. 196, dic. 2018, doi: 10.1007/s12046-018-0965-0.
- [44] M. Li, H. Hao, Y. Shi, y Y. Hao, «Specimen shape and size effects on the concrete compressive strength under static and dynamic tests», *Constr. Build. Mater.*, vol. 161, pp. 84-93, feb. 2018, doi: 10.1016/j.conbuildmat.2017.11.069.
- [45] G. Habbar, A. Maizia, A. Hocine, J. Ribeiro, y M. H. Dhaou, «Micromechanical Analysis of a Bio-Sandwich Application for Cylinder under Pressure», *J. Compos. Sci.*, vol. 6, n.º 3, p. 69, feb. 2022, doi: 10.3390/jcs6030069.
- [46] Y. Cao, W. Wang, y Q. Wang, «Application of mechanical model for natural fibre reinforced polymer composites», *Mater. Res. Innov.*, vol. 18, n.º sup2, pp. S2-354-S2-357, may 2014, doi: 10.1179/1432891714Z.000000000431.
- [47] P. Ewart y J. Verbeek, «Using micro-mechanical modelling to predict short-fibre composite properties in computer-aided design of sporting equipment», *Sports Eng.*, vol. 13, n.º 2, pp. 73-81, ene. 2011, doi: 10.1007/s12283-010-0057-9.
- [48] J. M. Díaz-Mendoza, D. J. Valles-Rosales, Y. H. Park, y R. C. Sabo, «Micromechanical Modeling for Tensile Properties of Wood Plastic Composites: Use of Pruned Waste from Pecan Orchards as Sustainable Material for Reinforcement of Thermoplastic Composite», *Polymers*, vol. 14, n.º 3, p. 504, ene. 2022, doi: 10.3390/polym14030504.
- [49] H. Yue, C. Lu, C. Wang, y F. Yang, «Optimizing tensile strength and failure prediction in hemp fiber composites: Coupling effects of microfibril angle and fiber orientation under off-axis loading», *Ind. Crops Prod.*, vol. 222, p. 119872, dic. 2024, doi: 10.1016/j.indcrop.2024.119872.
- [50] S. Xu, H. Yang, T. Li, y Y. Zhang, «Data-driven prediction of mechanical properties of 3D-printed dual-material composites based on deep transfer learning», *Compos. Part Appl. Sci. Manuf.*, vol. 198, p. 109083, nov. 2025, doi: 10.1016/j.compositesa.2025.109083.
- [51] E. A. W. de Menezes, L. Friedrich, A. Colpo, y S. C. Amico, «Chapter 5 - Micromechanics of Short-Fiber and Particulate Composites», en *Unsaturated Polyester Resins*, S. Thomas, M. Hosur, y C. J. Chirayil, Eds., Elsevier, 2019, pp. 125-152. doi: 10.1016/B978-0-12-816129-6.00005-3.
- [52] S. David Müzel, E. P. Bonhin, N. M. Guimarães, y E. S. Guidi, «Application of the Finite Element Method in the Analysis of Composite Materials: A Review», *Polymers*, vol. 12, n.º 4, p. 818, abr. 2020, doi: 10.3390/polym12040818.
- [53] N. Shetty, S. M. Shahabaz, S. S. Sharma, y S. Divakara Shetty, «A review on finite element method for machining of composite materials», *Compos. Struct.*, vol. 176, pp. 790-802, sep. 2017, doi: 10.1016/j.compstruct.2017.06.012.
- [54] W. Hou, X. Xu, H. Wang, y L. Tong, «Bending behavior of single hat-shaped composite T-joints under out-of-plane loading for lightweight automobile structures», *J. Reinf. Plast. Compos.*, vol. 37, n.º 12, pp. 808-823, 2018, doi: 10.1177/0731684418764608.
- [55] A. Alade y A. Ibrahim, «Application of Finite Element Method for Mechanical Characterization of Wood and Reconstituted Lignocellulosic-Based Composites – A Review», *Recent Prog. Mater.*, vol. 05, n.º 01, pp. 1-37, ene. 2023, doi: 10.21926/rpm.2301003.
- [56] M.-K. Hsu *et al.*, «A deep learning empowered smart representative volume element method for long fiber woven composites», *Front. Mater.*, vol. 10, p. 1179710, may 2023, doi: 10.3389/fmats.2023.1179710.
- [57] A. Wendling, J. L. Daniel, G. Hivet, E. Vidal-Sallé, y P. Boisse, «Meshing Preprocessor for the

Mesoscopic 3D Finite Element Simulation of 2D and Interlock Fabric Deformation», *Appl. Compos. Mater.*, vol. 22, n.º 6, pp. 869-886, dic. 2015, doi: 10.1007/s10443-015-9441-8.

[58] M. Rehan, T. He, D. Tahir, A. K. Khalil, W. S. Yip, y S. S. To, «3D Finite element modeling and experimental investigation of micro milling of laser powder bed fusion fabricated Ti6Al4V», *Results Eng.*, vol. 26, p. 104635, jun. 2025, doi: 10.1016/j.rineng.2025.104635.

[59] M. Mudabbirudin, J. Takacs, A. Mosavi, F. Imre, y N. Nabipour, «Deep Learning and Machine Learning for Materials Design», en *2024 IEEE 6th International Symposium on Logistics and Industrial Informatics (LINDI)*, 2024, pp. 73-82. doi: 10.1109/LINDI63813.2024.10820388.

[60] W. Gao *et al.*, «Accurately Predicting Multiple Performance of 3D Printing Photopolymers Using Ensemble Learning», *ACS Appl. Polym. Mater.*, vol. 6, n.º 8, pp. 4501-4508, 2024, doi: 10.1021/acsapm.3c03102.

[61] P. Guo, W. Meng, M. Xu, V. C. Li, y Y. Bao, «Predicting Mechanical Properties of High-Performance Fiber-Reinforced Cementitious Composites by Integrating Micromechanics and Machine Learning», *Materials*, vol. 14, n.º 12, p. 3143, jun. 2021, doi: 10.3390/ma14123143.

[62] S.-J. Huang, Y. Adityawardhana, y J. Sanjaya, «Predicting Mechanical Properties of Magnesium Matrix Composites with Regression Models by Machine Learning», *J. Compos. Sci.*, vol. 7, n.º 9, p. 347, ago. 2023, doi: 10.3390/jcs7090347.

[63] M. L. Bødker, M. Bauchy, T. Du, J. C. Mauro, y M. M. Smedskjaer, «Predicting glass structure by physics-informed machine learning», *Npj Comput. Mater.*, vol. 8, n.º 1, p. 192, sep. 2022, doi: 10.1038/s41524-022-00882-9.

[64] D. Jha *et al.*, «Enabling deeper learning on big data for materials informatics applications», *Sci. Rep.*, vol. 11, n.º 1, p. 4244, feb. 2021, doi: 10.1038/s41598-021-83193-1.

[65] M. Shirinbayan, S. Nouria, J. Zghal, y J. Fitoussi, «A hybrid approach for predicting fatigue life of fiber-reinforced polypropylene composite (PPGF40): Integrating micromechanical modelling», *Compos. Part C Open Access*, vol. 18, p. 100660, oct. 2025, doi: 10.1016/j.jcomc.2025.100660.

[66] A. Seidel, B. F. Sørensen, y K. Drechsler, «Modelling fatigue damage in unidirectional fibre composites using a hybrid analytical–numerical approach», *Compos. Part B Eng.*, vol. 305, p. 112667, oct. 2025, doi: 10.1016/j.compositesb.2025.112667.