



SECRETARIA DE EDUCACIÓN PÚBLICA
TECNOLÓGICO NACIONAL DE MÉXICO
INSTITUTO TECNOLÓGICO DE MÉRIDA

ITM

**“Prognosis de Daño Estructural en Materiales
Compuestos mediante Técnicas de Aprendizaje
Profundo para Redes de Sensores Energéticamente
Sustentables”**

TESIS DE POSGRADO

PARA OPTAR AL TÍTULO DE:

MAESTRO EN INGENIERÍA

PRESENTA:

ISAAC GUIBALDO VILLAJUANA HERNÁNDEZ

DIRECTOR:


JOSÉ AGUSTÍN HERNÁNDEZ BENITEZ

CODIRECTOR:

ABRAHAM ISAÍAS BALAM MENA

**MÉRIDA, YUCATÁN, MÉXICO
2020**

REVISORES DE LA TESIS

	Firma	Fecha de revisión
Director: Dr. José Agustín Hernández Benítez TecNM / Instituto Tecnológico de Mérida		01/06/26
Codirector: Dr. Abraham Isaías Balam Mena Centro de Investigación Científica de Yucatán		04/06/2026
Revisor 1: Dr. José Ramón Atoche Enseñat TecNM / Instituto Tecnológico de Mérida		04/06/2026
Revisor 2: Dr. Víctor Sandoval Curmina TecNM / Instituto Tecnológico de Mérida		03/06/2026
Revisor 3: Dr. Alejandro Arturo Castillo Atoche TecNM / Instituto Tecnológico de Mérida		04/06/2026

OFICIO DE AUTORIZACIÓN DE IMPRESIÓN

CARTA DE CESIÓN DE DERECHOS

En la ciudad de Mérida, Yucatán el día 03 de junio de 2026, la que suscribe ISAAC GUIBALDO VILLAJUANA HERNÁNDEZ, con número de control G18080243, alumno de la **Maestría en Ingeniería**, manifiesta que el presente trabajo de Tesis realizado bajo la dirección del Dr. José Agustín Hernández Benítez y codirección del Dr. Abraham Isaías Balam Mena, cede los derechos para su difusión, en su totalidad o en partes, con fines académicos o de investigación del documento de tesis titulado **“Prognosis de Daño Estructural en Materiales Compuestos mediante Técnicas de Aprendizaje profundo para Redes de Sensores Energéticamente Sustentables”** al Tecnológico Nacional de México.

Para reproducir el contenido textual, gráficas, código, fórmulas o datos del trabajo, se requiere el permiso del alumno y del director de la tesis.

Si se otorga el permiso, el usuario deberá dar los créditos correspondientes tanto a los autores, cómo al Tecnológico Nacional de México y citar la fuente del mismo.

ATENTAMENTE



Isaac Guibaldo Villajuana Hernández

Maestría en Ingeniería

ACUERDO PARA USO DE OBRA (TESIS DE GRADO)

A QUIEN CORRESPONDA

PRESENTE

Por medio del presente escrito, ISAAC GUIBALDO VILLAJUANA HERNÁNDEZ hace constar que es titular intelectual de la obra denominada: “PROGNOSIS DE DAÑO ESTRUCTURAL EN MATERIALES COMPUESTOS MEDIANTE TÉCNICAS DE APRENDIZAJE PROFUNDO PARA REDES DE SENSORES ENERGÉTICAMENTE SUSTENTABLES”, (en lo sucesivo la OBRA) en virtud de lo cual autoriza al Tecnológico Nacional de México/Instituto Tecnológico de Mérida (en lo sucesivo TECN/IT Mérida) para que efectúe resguardo físico y/o electrónico mediante copia digital o impresa para asegurar su disponibilidad, divulgación, comunicación pública, distribución, transmisión, reproducción, así como digitalización de la misma con fines académicos y sin fines de lucro como parte del Repositorio Institucional del TECN/IT Mérida.

De igual manera, es deseo del AUTOR establecer que esta autorización es voluntaria y gratuita, y que de acuerdo a lo señalado en la Ley Federal del Derecho de Autor y la Ley de Propiedad Industrial el TECN/IT Mérida cuenta con mi autorización para la utilización de la información antes señalada, estableciendo que se utilizará única y exclusivamente para los fines antes señalados. El AUTOR autoriza al TECN /IT Mérida a utilizar la obra en los términos y condiciones aquí expresados, sin que ello implique se le conceda licencia o autorización alguna o algún tipo de derecho distinto al mencionada respecto a la “propiedad intelectual” de la misma OBRA; incluyendo todo tipo de derechos patrimoniales sobre obras y creaciones protegidas por derechos de autor y demás formas de propiedad intelectual reconocida o que lleguen a reconocer las leyes correspondientes. Al reutilizar, reproducir, transmitir y/o distribuir la OBRA se deberá reconocer y dar créditos de autoría de la obra intelectual en los términos especificados por el propio autor, y el no hacerlo implica el término de uso de esta licencia para los fines estipulados. Nada de esta licencia menoscaba o restringe los derechos patrimoniales y morales del AUTOR.

De la misma manera, se hace manifiesto que el contenido académico, literario, la edición y en general de cualquier parte de la OBRA son responsabilidad de AUTOR, por lo que se deslinda al (TECN/IT Mérida) por cualquier violación a los derechos de autor y/o propiedad intelectual, así como cualquier responsabilidad relacionada con la misma frente a terceros. Finalmente, el AUTOR manifiesta que estará depositando la versión final de su documento de Tesis, OBRA, y cuenta con los derechos morales y patrimoniales correspondientes para otorgar la presente autorización de uso.

En la ciudad de Mérida, del estado de Yucatán a los 03 días del mes de junio de 2026.

Atentamente,



ISAAC GUIBALDO VILLAJUANA HERNÁNDEZ

Aunque este trabajo hubiere servido para el Examen de Grado y hubiera sido aprobado por el sínodo, sólo el autor es responsable de las ideas emitidas en él.

“Y me dijo más de una vez,
yo solo criaré leones para cazar”

-Yuriy Shkvarko Sosnoff (QEPD) & Alejandro Castillo Atoche

Agradecimientos

Al SECIHTI por la beca de posgrado otorgada No. 4021055 (CVU 2006896).

Al Instituto Tecnológico de Mérida por la mentoría y el acceso a instalaciones y equipo necesarios para la realización de este trabajo de tesis.

A la Universidad Autónoma de Yucatán (UADY) por el acceso a equipos y laboratorio necesarios para la realización de este trabajo de Tesis.

Al Centro de Investigación Científica de Yucatán (CICY) por el acceso a los datos de muestra de los materiales analizados en la realización de este proyecto de Tesis.

A los profesores del posgrado en Ingeniería Especialidad Mecatrónica por la aportación de sus conocimientos a mi formación durante la realización del mismo.

A mi director de Tesis, Dr. José Agustín Hernández Benítez por su valiosa asesoría, apoyo y confianza, los cuales contribuyeron a darle estructura y dirección a este proyecto y a mi formación como profesional.

A mi codirector de Tesis, Dr. Abraham Isaías Balam Mena por su valiosa contribución y asesoramiento en la revisión y edición puntuales de este proyecto.

Al Dr. Alejandro Arturo Castillo Atoche por la confianza, asesoría y consejos durante mi estancia en el Laboratorio Robótica e Industria 4.0, donde además de facilitar mi acceso a las herramientas y materiales empleados en el desarrollo de trabajo me integró con un excelente equipo de trabajo.

Al Dr. Fráncis Avilés Cetina, por el acceso a los datos, instalaciones y reuniones necesarias para el desarrollo de este proyecto, pero sobre todo por su excelente trato, por la confianza y comentarios puntuales durante las sesiones de trabajo.

Al Dr. Johan Jair Estrada López por la motivación indirecta que me otorgaron sus comentarios puntuales y recomendaciones durante el desarrollo de este trabajo.

A la ahora Dra. Gaby Carolina Uribe Riestra y al (próximamente) Dr. Julio César Heredia Lozano por su apoyo, asesoría y aclaración de dudas durante el desarrollo de este proyecto.

A mis colegas del Laboratorio Robótica e Industria 4.0, por sus observaciones puntuales y comentarios durante las sesiones de seminario, así como por las risas y diversión durante mi estancia.

A mis padres, Rebeca y Guibaldo, por ser mis primeros mentores y quienes me impulsaron a investigar y resolver de manera autodidacta cada una de mis inquietudes.

A todas las personas que han contribuido en mi desarrollo personal directa o indirectamente a lo largo de estos años.

Resumen

El creciente uso de materiales compuestos en el diseño de aplicaciones de ingeniería ha propiciado que la integración e implementación de sistemas de Monitoreo de Salud Estructural (SHM) sea indispensable en industrias como la aeroespacial y automotriz. Debido a la naturaleza compleja de estos materiales, los sensores utilizados en dichos sistemas deben garantizar no solo sustentabilidad energética y precisión, sino también eficiencia computacional para la predicción de fallos estructurales en tiempo real.

Esta investigación propone el diseño y validación de una herramienta de software para la prognosis de daño estructural, basado en algoritmos de aprendizaje profundo. El objetivo principal consiste en modelar la evolución temporal de la degradación en materiales compuestos de fibra de vidrio modificados con nanotubos de carbono (CNT) sujetos a desprendimiento. Para ello, se utilizaron datos provenientes de pruebas de flexión mediante cargas monotónicas aplicadas hasta el fallo de los materiales.

La evaluación experimental demostró una excelente capacidad de generalización en ambas arquitecturas (GRU y LSTM), sin indicios de sobreajuste y logrando converger en menos de 20 épocas. Sin embargo, el modelo GRU mostró un rendimiento predictivo superior: logró estabilizarse más rápido y alcanzó un RMSE de validación del 2.5 % y un MAE del 1.5 %. Esto representa una reducción del error del 37.5 % y 40.0 %, respectivamente, frente a las métricas obtenidas por el modelo LSTM (4.0 % de RMSE y 2.5 % de MAE).

Se concluye que los modelos de aprendizaje profundo desarrollados permiten una estimación precisa y eficiente del daño estructural en los materiales estudiados, validando su viabilidad para ser integrados en redes de sensores autónomos y sustentables.

Abstract

The increasing use of composite materials in engineering design has made the integration and implementation of Structural Health Monitoring (SHM) systems indispensable in industries such as the aerospace and automotive sectors. Due to the complex nature of these materials, the sensors used in such systems must ensure not only energy sustainability and accuracy, but also computational efficiency for real-time structural failure prediction.

This research proposes the design and validation of a software tool for structural damage prognosis, based on deep learning algorithms. The main objective is to model the temporal evolution of degradation in fiberglass composite materials modified with carbon nanotubes (CNTs) subjected to debonding. For this purpose, data from bending tests under monotonic loads applied until material failure were utilized.

The experimental evaluation demonstrated excellent generalization capabilities in both architectures (GRU and LSTM), showing no signs of overfitting and converging in fewer than 20 epochs. However, the GRU model exhibited superior predictive performance: it stabilized faster and achieved a validation RMSE of 2.5 % and a MAE of 1.5 %. This represents an error reduction of 37.5 % and 40.0 %, respectively, compared to the metrics obtained by the LSTM model (4.0 % RMSE and 2.5 % MAE).

It is concluded that the developed deep learning models allow for an accurate and efficient estimation of structural damage in the studied materials, validating their viability for integration into autonomous and sustainable sensor networks.

Índice general

Índice de Figuras	8
Índice de Tablas	10
1. Introducción	12
1.1. Antecedentes y justificación	12
1.2. Planteamiento del problema	15
1.3. Objetivos	15
1.3.1. General	16
1.3.2. Específicos	16
1.4. Vinculación	16
1.5. Estado del arte	17
1.6. Impacto Industrial del Sistema de Prognosis de Daño Estructural	19
1.7. Estructura de la tesis	20
2. Marco Teórico	21
2.1. Monitoreo de Salud Estructural	21
2.1.1. Prognosis de daño	23
2.2. Redes de sensores inalámbricas e internet de las cosas	24
2.2.1. Topologías de Redes de Sensores Inalámbricas	25
2.2.2. Aplicación de WSN en SHM con materiales compuestos	25
2.3. Inteligencia Artificial	26
2.3.1. Machine Learning	27
2.3.2. Random Forest	27
2.3.3. Random Forest aplicado al monitoreo de salud estructural	29
2.3.4. Redes Neuronales Profundas	29
2.4. Deep Learning	30
2.5. Redes Neuronales Recurrentes	31
2.5.1. Long Short-Term Memory	32
2.5.2. Gated Recurrent Unit	33
2.5.2.1. Funciones de activación	34
2.6. Materiales Compuestos	35
2.6.1. Monitoreo de salud estructural en compuestos	35
2.6.2. Modelos de inteligencia artificial y machine learning en compuestos	36
2.6.3. Nanotubos de Carbono	37

2.6.4. Nanotubos de Carbono en Monitoreo de Salud Estructural	38
3. Prognosis en compuestos con fibras de vidrio modificadas con nanotubos de carbono	39
3.1. Importancia de prognosis con inteligencia artificial y redes de sensores inalámbricas	39
3.2. Prognosis en fibras de vidrio modificadas con nanotubos de carbono con machine learning	40
3.3. Análisis y caracterización de las muestras	40
3.3.1. Criterios de clasificación de daño	43
3.4. Machine Learning / Deep Learning	43
3.4.1. Modelado secuencial mediante redes neuronales recurrentes avanzadas	43
3.4.1.1. Arquitectura de Memoria a Corto y Largo Plazo	44
3.4.2. Preparación y gestión del programa	44
3.4.3. Preprocesamiento y gestión de datos	44
3.4.4. Arquitectura del modelo secuencial	45
3.4.5. Protocolo de entrenamiento y optimización	45
3.4.6. Evaluación del desempeño	45
3.4.7. Implementación Algorítmica del Sistema Predictivo	46
4. Resultados/Discusión	48
4.1. Prognosis con modelos de aprendizaje automático	48
4.2. Prognosis con arquitecturas de aprendizaje profundo	49
4.2.1. Prognosis con long-short term memory	50
4.2.1.1. Resultados de la señal 08-10'	50
4.2.1.2. Resultados de la señal 10-12'	53
4.2.2. Prognosis con gated recurrent unit	56
4.2.2.1. Resultados en los nodos 08-10'	57
4.2.2.2. Resultados de la señal 10-12'	60
5. Conclusiones y recomendaciones	64
Referencias	66

Índice de figuras

1.1. Formas de falla típicas en materiales compuestos fibrorreforzados [1] . . .	13
1.2. Representación gráfica de un sistema de monitoreo de salud estructural avanzado	13
1.3. Diagrama de sistemas de WSN empleados para el monitoreo de salud estructural [2]	17
2.1. Esquema de jerarquía de identificación de daño [3]	22
2.2. Esquema de estrategias de pronosis de daño. Adoptado de [4]	24
2.3. Topología de Estrella en WSN [5]	25
2.4. Diagrama relacional de IA y ML	27
2.5. Modelo Random Forest (adaptado de [6])	28
2.6. Red Neuronal Recurrente en su forma más básica.	31
2.7. Diagrama básico de función de transmisión unitaria de LSTM	33
2.8. Diagrama básico de función de transmisión unitaria de GRU	34
2.9. Funciones de activación tanh y sigmoide. Adoptado de [7]	34
3.1. Diagrama de flujo del procesamiento de datos para predicción de daño. Adaptado de [8]	40
3.2. Análisis dimensional de una muestra de fibra de vidrio modificada con CNT	41
3.3. Software de procesamiento de datos de SHM [9]	42
3.4. Maquina Universal Shimadzu AG-1 (superior) y diagrama de cargas monotónicas aplicadas (inferior)	42
3.5. Pseudocódigo de funcionamiento del programa de entrenamiento	46
4.1. Diagrama de señal representativa seleccionada en CN-F-D-S1.	48
4.2. Métricas de evaluación de desempeño del modelo Random Forest	49
4.3. Diagrama de señal representativa 11-9'	49
4.4. Diagrama de señales representativas seleccionadas en CNT-D-S2.	50
4.5. Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en 08-10' con LSTM .	51
4.6. Entrenamiento de modelo con arquitectura LSTM en 08-10'	52
4.7. Matriz de confusión con arquitectura LSTM en 08-10'	52
4.8. Resultados de Pronosis de daño con arquitectura LSTM en 08-10'	53
4.9. Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (10-12') con LSTM	54
4.10. Entrenamiento de modelo con arquitectura LSTM en 10-12'	55
4.11. Matriz de confusión con arquitectura LSTM en 10-12'	55

4.12. Resultados de Prognosis de daño con arquitectura LSTM en 10-12'	56
4.13. Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (08-10') con GRU	57
4.14. Entrenamiento de modelo con arquitectura GRU en 08-10'	58
4.15. Matriz de confusión con arquitectura GRU en 08-10'	59
4.16. Resultados de Prognosis de daño con arquitectura GRU en 08-10'	60
4.17. Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (10-12') con GRU	61
4.18. Entrenamiento de modelo con arquitectura GRU en 10-12'	61
4.19. Matriz de confusión con arquitectura GRU en 10-12'	62
4.20. Resultados de Prognosis de daño con arquitectura GRU en 10-12'	63

Índice de tablas

- 3.1. Criterios de clasificación de daño en compuestos con nanoestructuras de carbono [8] 43
- 4.1. Métricas de desempeño de la arquitectura LSTM en la muestra 08-10' . . 53
- 4.2. Métricas de desempeño de la arquitectura LSTM en la muestra 10-12' . . 56
- 4.3. Métricas de desempeño de la arquitectura GRU en la muestra 08-10' . . 59
- 4.4. Métricas de desempeño de la arquitectura GRU en la muestra 10-12' . . 62

Capítulo 1

Introducción

1.1. Antecedentes y justificación

La evolución tecnológica reciente ha impulsado la integración de materiales avanzados en el diseño de sistemas mecánicos y estructurales. En este contexto, los materiales compuestos han adquirido un mayor protagonismo frente a otras alternativas debido a la destacada relación resistencia-peso que poseen, promoviendo así su integración en sectores donde la rigidez y baja densidad son factores críticos, tales como la construcción, la industria naval, automotriz y aeroespacial.

Este tipo de materiales compuestos, cuando son reforzados con fibras, se caracterizan por ser de naturaleza anisotrópica, es decir, que sus propiedades mecánicas superiores dependen de la orientación de sus fibras internas. Dicho parámetro es completamente controlable en el proceso de manufactura, no obstante, su exposición a factores ambientales externos puede derivar en mecanismos de falla interna tales como microfisuras, agrietamientos en la matriz y delaminación (Figura 1.1), cuya detección mediante una inspección visual convencional puede resultar una tarea extenuante. De estos desperfectos, la delaminación representa el problema más crítico, pues compromete la integridad de la estructura sin manifestar indicadores de daño en su superficie, lo cual puede derivar en consecuencias catastróficas de no tomarse medidas en el momento justo.

Ante tal riesgo, es imprescindible crear e implementar sistemas capaces de diagnosticar el estado físico actual de la estructura, identificar vulnerabilidades potenciales o existentes, así como predecir su comportamiento a futuro. Ello garantiza una toma de decisiones estratégica, que permite no solo optimizar los costos de mantenimiento sino, primordialmente, garantizar la seguridad operativa y la de sus usuarios. Para afrontar dicha problemática, la industria ha recurrido por décadas al uso de Ensayos No Destructivos (NDT, por sus siglas en inglés), como ultrasonido, rayos X y termografía para la detección de discontinuidades tanto en los procesos de control de calidad como durante la fase operativa del material. Si bien estas técnicas han demostrado ser confiables y robustas, su implementación exige la intervención humana activa mediante el análisis *in-situ*, es decir, se debe acceder físicamente a la estructura con el




Figura 1.1: Formas de falla típicas en materiales compuestos fibrorreforzados [1]

equipo necesario para realizar dichos ensayos, lo cual incrementa considerablemente la complejidad operativa y, por ende, su costo.

Dicha limitación ha favorecido el uso de sistemas como el Monitoreo de Salud Estructural (SHM, por sus siglas en inglés), el cual representa una alternativa eficaz para el diagnóstico mecanizado y continuo. Los sistemas de este tipo se fundamentan en la detección automatizada de daño a través del procesamiento de datos recolectados mediante una o varias redes de sensores integradas en zonas estratégicas de la estructura (Figura 1.2).




Figura 1.2: Representación gráfica de un sistema de monitoreo de salud estructural avanzado

En las arquitecturas de redes de sensores tradicionales, el uso de cableado para el suministro energético y la transmisión de datos es indispensable, lo cual restringe el número de nodos operables y por consiguiente, su escalabilidad [10]. Ante esta limitación, las redes de sensores inalámbricas (WSN, por sus siglas en inglés) han cobrado

gran relevancia por ofrecer mayor flexibilidad y facilidad de despliegue en sistemas escalables y con una mayor densidad de sensores. Se proyecta que el valor de mercado de estas tecnologías aumentará de 15.9 a 79.6 mil millones de dólares entre 2025 y 2035. Esta expansión es impulsada por la convergencia tecnológica entre el Internet de las Cosas (*IoT*), el cómputo en el borde (*Edge Computing*) y el procesamiento de datos en tiempo real.

Por otra parte, los sistemas de SHM se han potenciado mediante la integración del Aprendizaje Automático (ML, por sus siglas en inglés) para el procesamiento de señales. A través de métodos estadísticos, estos modelos permiten clasificar y predecir el comportamiento mecánico de los materiales. Sin embargo, su capacidad diagnóstica suele limitarse a clasificaciones binarias, determinando únicamente la presencia o ausencia de daño, lo cual restringe la obtención de información detallada sobre la localización o severidad del daño sin recurrir a arquitecturas híbridas de mayor complejidad.

Para superar tales restricciones, se ha impulsado el uso de modelos de Aprendizaje Profundo (Deep Learning, DL) y redes neuronales, los cuales facilitan el análisis de datos estructurados en series de tiempo. Bajo este enfoque, se incorpora la dimensión temporal al modelado, permitiendo identificar patrones complejos en la señal, así como estimar la progresión del daño en el material y predecir el momento en que este pueda presentar fallas mecánicas.

Para llevar esto a cabo, se hace uso de redes de sensores de diversos tipos, entre ellos sensores piezorresistivos basados en nanoestructuras de carbono que permiten registrar variaciones, deformación y respuesta electromecánica del material en diferentes puntos de la estructura. Sin embargo, la cantidad de información que estos sistemas generan es masiva, complicando la interpretación manual de los datos recolectados. Esta limitante ha impulsado la adopción de técnicas de Inteligencia Artificial, abarcando desde algoritmos de Aprendizaje Automático (*Machine Learning*, ML) hasta arquitecturas de aprendizaje profundo (*Deep Learning*, DL) como Redes Neuronales Convolucionales (*Convolutional Neural Networks*, CNN) y Recurrentes (*Recurrent Neural Networks*, RNN).

Tomando en cuenta estos factores, el objetivo central de este proyecto consiste en predecir daño estructural en materiales compuestos laminados reforzados con nanotubos de carbono mediante arquitecturas de DL. Para ello, se desarrolló un sistema computacional que permitió modelar, a través de arquitecturas de Redes Neuronales Recurrentes (RNN), el comportamiento piezorresistivo del material bajo cargas monotónicas.

Bajo este enfoque, esta investigación busca aportar una estrategia de modelado computacional robusta y validada que sirva como base para el desarrollo futuro de sistemas de monitoreo autónomo. La eficiencia de estos modelos es clave para facilitar su integración en redes de sensores inalámbricos de bajo consumo y energéticamente sustentables.

1.2. Planteamiento del problema

Los materiales compuestos laminados reforzados con fibra de vidrio han ganado relevancia dentro de la ingeniería moderna debido a su alta relación resistencia-peso. No obstante, la integración de nanotubos de carbono (CNT), si bien mejora las propiedades mecánicas y añade capacidades de auto-detección (piezorresistividad), incrementa exponencialmente la complejidad del análisis de integridad. La naturaleza anisotrópica y los mecanismos de fallo multiescala, como la micro-fisuración de la matriz y la delaminación, presentan comportamientos no lineales que los modelos constitutivos tradicionales no logran capturar con precisión en condiciones operativas variables.

Actualmente, el SHM depende en gran medida de inspecciones no destructivas intermitentes o de modelos físicos (elementos finitos) que son computacionalmente costosos y difíciles de ejecutar en tiempo real. Estas metodologías suelen ser reactivas: detectan el daño cuando ya es incipiente, pero fallan en la prognosis o predicción de la vida útil remanente. Además, los sistemas cableados convencionales resultan imprácticos por su peso y costo de instalación en estructuras extensas, mientras que las soluciones inalámbricas enfrentan el "cuello de botella" del consumo energético, limitando su autonomía y la frecuencia de muestreo de datos.

A pesar del avance en la adquisición de datos, existe una desconexión crítica entre la recolección de señales y su interpretación predictiva bajo restricciones de energía. Se requiere un enfoque que trascienda la simple detección. Aquí radica la necesidad de implementar arquitecturas de Deep Learning, específicamente redes LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit), las cuales son capaces de modelar dependencias temporales y secuencias históricas de degradación.

Sin embargo, el despliegue de estos modelos en entornos reales se ve obstaculizado por la falta de software especializado que integre:

- El procesamiento de datos provenientes de redes de sensores inalámbricos energéticamente sustentables.
- La capacidad de realizar prognosis precisa del daño acumulado en materiales dopados con nanotubos de carbono.

Por lo tanto, el problema central es la ausencia de un sistema de modelado robusto y eficiente que traduzca las señales complejas y ruidosas de una red de sensores de bajo consumo en pronósticos confiables. Sin una herramienta que combine la eficiencia algorítmica de las arquitecturas recurrentes con la autonomía operativa de sensores sustentables, la transición hacia un mantenimiento predictivo en tiempo real en estructuras compuestas de última generación seguirá siendo técnicamente inviable.

1.3. Objetivos

La presente tesis de maestría aborda la problemática descrita mediante la propuesta e integración de un sistema de modelado computacional, desarrollado en Python,

destinado al pronóstico de degradación estructural en materiales compuestos laminados basados en nanoestructuras de carbono.

1.3.1. General

Desarrollar un sistema de modelado computacional basado en técnicas de Deep Learning para el pronóstico de daño estructural en materiales compuestos laminados con nanotubos de carbono, validado mediante datos experimentales de resistividad eléctrica.

1.3.2. Específicos

1. Analizar el estado del arte en métodos de Structural Health Monitoring y en técnicas de Deep Learning aplicadas a la detección y pronóstico de daño en materiales piezorresistivos.
2. Seleccionar, con base en la literatura especializada, las arquitecturas de redes neuronales y algoritmos de Machine Learning más pertinentes para el modelado de series de tiempo en dicho contexto.
3. Implementar algoritmos en Python para realizar un estudio comparativo entre modelos de Machine Learning (Random Forest) y Deep Learning (LSTM y GRU) en tareas de regresión y detección de anomalías.
4. Validar la estimación de la respuesta de resistividad eléctrica con datos reales provenientes de pruebas de flexión a cuatro puntos en materiales compuestos laminados con nanoestructuras de carbono.
5. Evaluar el desempeño de los modelos seleccionados mediante métricas de error y precisión para determinar su viabilidad como herramienta de pronóstico.

1.4. Vinculación

El presente proyecto se realizó en conjunto con el Laboratorio de Robótica e Industria 4.0 de la Facultad de Ingeniería de la Universidad Autónoma de Yucatán (FiUADY), dirigido por el Dr. Alejandro Arturo Castillo Atoche, así como con el Centro de Investigación Científica de Yucatán (CICY), dirigido por el Dr. Francis Avilés Cetina. Su realización constituyó un esfuerzo de investigación colaborativa entre instituciones que permitió el desarrollo experimental mediante datos de muestreo actuales y materiales de relevancia global, lo que subraya la pertinencia y el valor científico de la presente investigación.

1.5. Estado del arte

En la última década, el tema de prognosis por daño ha cobrado gran relevancia a partir de la integración de modelos de aprendizaje profundo (Deep Learning, DL) e Inteligencia Artificial (Artificial Intelligence, AI) en estructuras y sistemas, principalmente en áreas de la ingeniería estructural, así como la industria aeroespacial y automotriz. Sin embargo, durante los últimos cinco años, la literatura se ha enfocado en la implementación de sistemas de evaluación de daño híbridos, los cuales fusionan métodos de evaluación no destructivos (NDT, por sus siglas en inglés) con sistemas de SHM para identificar y localizar el daño en diversos tipos de materiales.

La literatura actual refleja un amplio interés en el uso de materiales basados en nanotubos de carbono (CNT) para el diseño de sensores, esto debido a sus excepcionales propiedades de sensibilidad y flexibilidad de diseño. Por ejemplo, en trabajos como [11], [12], [13] y [14] el enfoque de investigación orbita en torno al uso de nanotubos de carbono multicapa (MWCNT) y polipropileno (PP) para la optimización y diseño de sensores piezoeléctricos de tensión, así como para su implementación en aplicaciones de redes de sensores inalámbricas (WSN) 1.3LoRa y dispositivos vestibles (wearables) táctiles aptos para aplicaciones biomédicas. Gül et. al. remarcan en [15] la necesidad




Figura 1.3: Diagrama de sistemas de WSN empleados para el monitoreo de salud estructural [2]

de desarrollar modelos de pronóstico capaces de revelar en tiempo real el crecimiento de delaminación en los materiales estudiados. Para ello, proponen una metodología de prognosis en materiales compuestos con delaminación basada en Redes neuronales profundas (DNN) y enfocada en la vida útil remanente (RUL) del material. En [16]

se plantea el uso de redes WSN y técnicas de ML para evaluar la calidad en frutas y predecir su tiempo de descomposición.

La integración de modelos de aprendizaje automático (Machine Learning, ML) y aprendizaje profundo (Deep Learning, DL) ha revolucionado la forma de realizar monitoreo estructural. El monitoreo efectivo de daño en estructuras es esencial para asegurar la seguridad y durabilidad en infraestructuras. Las técnicas tradicionales de monitoreo enfrentan desafíos como altos costos, invasividad y falta de sensibilidad para detectar cambios incipientes. Aquí es donde el aprendizaje automático mediante técnicas de DL ofrece una solución prometedora al permitir el análisis de grandes volúmenes de datos de sensores distribuidos en la estructura, identificando patrones sutiles que podrían indicar daños. La capacidad de adaptación y aprendizaje continuo del machine learning mejora la precisión del monitoreo con el tiempo.

El uso de modelos DL híbridos se ha vuelto popular en los últimos años debido a los beneficios obtenidos al utilizar modelos de aprendizaje para tareas específicas. Respecto al uso de modelos de DL, el estado del arte actual contiene proyectos de investigación que combinan el uso de Redes Neuronales Convolucionales (CNN), las cuales son excelentes para la extracción de características a partir de imágenes, en conjunto con arquitectura tales como Long Short-Term Memory (LSTM) o Gated Recurrent Unit (GRU) para el estudio de las propiedades de diversos tipos de materiales compuestos así como para la optimización en el funcionamiento de sistemas SHM. Por ejemplo, en [17] se propone el uso de modelos CNN-LSTM para predecir las propiedades mecánicas en materiales de fibra de carbono. De igual manera, en [18] se propone el uso de un sistema de meta-aprendizaje que integra datos 3D microestructurales de una rama de CNN y LSTM para predecir la durabilidad de interfaces de metal-concreto en materiales compuestos de construcción con datos de historial limitados. Por otra parte, en [19] se hace uso de modelos CNN-GRU para recuperar información de monitoreo perdida en sistemas SHM, lo cual demuestra la pertinencia de este tipo de arquitecturas al integrar el uso de *memorias* pasadas para la predicción de comportamientos a futuro.

Respecto a la implementación de estas arquitecturas estado del arte actual muestra un amplio interés en el uso de la arquitectura Gated Recurrent Unit (GRU) aplicada al cómputo de borde (edge computing, EC) en sistemas IoT. En trabajos como [20] se propone un modelo de regresión múltiple que aprovecha el uso de redes neuronales GRU para predecir el uso de recursos en nodos EC. En [21] se propone el uso de modelos temporales ligeros basados en arquitecturas LSTM y GRU para el reconocimiento de comportamiento en tiempo real para el aprovechamiento de métricas Sin embargo, su aplicación comparativa en la prognosis por daño en materiales compuestos es limitada.

En este contexto, la literatura reciente reporta avances significativos. Por ejemplo, en 2021 Jung et al. [22] desarrollaron un sistema SHM empleando la Transformada de Wavelet Discreta (*Discrete Wavelet Transform*, DWT) para caracterizar y modelar en 3D el impacto por carga en cintas de PVDF a partir del procesamiento y clasificación de imágenes mediante CNN. Por otra parte, en [23] Zhang et al. proponen un método basado en Ondas de Lamb utilizando LightGBM, un modelo de ML de alto rendimiento

para el diagnóstico eficiente de condiciones del material. No obstante, aunque estos enfoques demuestran gran eficacia en tareas de clasificación estática o procesamiento de imágenes, presentan limitaciones para modelar la evolución temporal del daño en secuencias de datos crudos, aspecto fundamental para una prognosis precisa.

Desde 2007, Farrar vislumbraba en [24] el potencial de desarrollo presente en esta área, así como los beneficios de salud y economía que representaría una exploración más detallada de la misma. De igual manera planteó en este artículo un panorama bien definido sobre los problemas a resolver para la integración de la prognosis de daño en sistemas de Monitoreo de Salud Estructural (*Structural Health Monitoring*, SHM), entre los cuales destaca la necesidad de mejorar las capacidades de modelado predictivo, así como la de cuantificar la incertidumbre obtenida durante la predicción. Esto se reflejó en el estado del arte de su época, donde a pesar de contar con estudios en cuanto a "daño de sistemas de ingeniería", en la mayoría de los casos la prognosis de daño se evadió por completo.

Ya en 2011 se pueden encontrar antecedentes sobre el interés creciente de implementar *sistemas neuronales estructurales* en proyectos de ingeniería, especialmente en campos como la mecánica o la industria aeroespacial. El uso de este tipo de sistemas conlleva el incremento en el número de sensores desplegados, así como el procesamiento en paralelo de procedimientos para el análisis del daño en materiales compuestos utilizados en aplicaciones críticas (Figura 1.1)

1.6. Impacto Industrial del Sistema de Prognosis de Daño Estructural

El sistema de prognosis de daño estructural propuesto en esta investigación tiene un impacto directo en sectores estratégicos que dependen de los materiales compuestos, tales como las industrias aeronáutica, automotriz, ferroviaria y de energía eólica (específicamente en palas de aerogeneradores). Mediante el uso de técnicas de aprendizaje profundo (Deep Learning), en particular las arquitecturas LSTM y GRU, este sistema procesa mediciones de resistividad eléctrica para anticipar fallas estructurales. Esto permite la transición de esquemas de mantenimiento preventivo a estrategias de mantenimiento predictivo, lo cual optimiza la seguridad operativa y reduce costos por paros imprevistos bajo las siguientes ventajas competitivas:

- Reducción de inspecciones visuales y destructivas: La validación con datos experimentales de pruebas de flexión a cuatro puntos demuestra que el modelo puede estimar la evolución del daño sin necesidad de ensayos mecánicos periódicos, disminuyendo costos operativos y tiempos de inactividad no programados
- Monitoreo continuo y autónomo: La naturaleza no intrusiva de las mediciones eléctricas permite integrar el sistema en procesos productivos existentes, facilitando la transición hacia esquemas de Mantenimiento Basado en Condición (CBM) y Gemelos Digitales (Digital Twins) en plantas manufactureras.

- Escalabilidad a diferentes configuraciones de material: El enfoque basado en redes neuronales recurrentes es adaptable a distintos tipos de nanoestructuras de carbono y configuraciones de laminado, lo que permite su transferencia tecnológica a múltiples líneas de producción sin rediseños completos

1.7. Estructura de la tesis

El presente documento se estructura en seis capítulos. El Capítulo 1 introduce la problemática, la justificación y los objetivos de este proyecto. En el Capítulo 2 se establece el marco teórico, abordando los conceptos fundamentales sobre materiales compuestos y Deep Learning requeridos para el desarrollo del sistema propuesto. En el Capítulo 3 se detalla la metodología empleada para la construcción, entrenamiento y validación de los modelos computacionales. Posteriormente, el Capítulo 4 expone los resultados experimentales y el análisis de desempeño de las arquitecturas implementadas. Finalmente, los Capítulos 5 y 6 presentan la discusión de los hallazgos, las conclusiones generales alcanzadas y las recomendaciones para futuras líneas de investigación derivadas de este proyecto.

Capítulo 2

Marco Teórico

2.1. Monitoreo de Salud Estructural

El Monitoreo de Salud Estructural (SHM, por sus siglas en inglés) es un término que emergió a finales de la década de los 80 a fin de asociar conceptos del sector salud, de control y de monitoreo a la ingeniería estructural. Boller et al. [25] lo definen como "la integración de dispositivos sensores, y posiblemente también actuadores, para el registro, análisis, localización y predicción de las condiciones de carga y daño de una estructura". De manera análoga, Farrar y Worden (2007) proponen en [24] la siguiente definición: es "el proceso de implementar una estrategia de identificación de daño para infraestructuras de ingeniería aeroespacial, civil y mecánica". Ambas definiciones establecen que el SHM va más allá de la simple observación e involucra un proceso sistémico continuo que facilita el análisis y la toma oportuna de decisiones.

Bajo este contexto, el daño se define en términos generales como cualquier cambio introducido en las propiedades materiales o geométricas de un sistema, incluyendo alteraciones en las condiciones de contorno y conectividad, que afecte negativamente su rendimiento actual o futuro [24]. Por lo tanto, el objetivo principal del SHM se enfoca en la vigilancia continua para gestionar y aplicar estrategias bien fundamentadas que permitan identificar estos cambios detrimentales. De esta manera, se facilita la toma de decisiones que garantizan no solo la operabilidad de las estructuras, sino también la seguridad de quienes las utilizan. cumplir con este objetivo, es necesario establecer cuáles son los elementos que conforman el proceso. De acuerdo con Gharrebaghi (2022), un sistema de SHM convencional se constituye de tres componentes principales:

- **Sensores:** Dispositivos alámbricos o inalámbricos capaces de detectar parámetros físicos (tales como temperatura, aceleración, deformación, etc.).
- **Unidad de procesamiento:** Etapa encargada de la adquisición, transmisión y almacenamiento de información detectada por la red de sensores.
- **Sistema de Interpretación de datos:** Etapa compuesta por métodos algorítmicos para el diagnóstico y administración de la información previamente procesada.

Este último elemento se compone a su vez de dos fases: Diagnóstico y Prognosis. Para asegurar la optimización en un sistema de SHM, el proceso no debe limitarse a una detección binaria del estado del material (dañado/no dañado). Bajo esta perspectiva, Rytter (1993) [26] estableció una jerarquización de la identificación de daño en niveles de complejidad creciente. Posteriormente, Farrar y Worden ampliaron esta taxonomía, añadiendo una etapa adicional de "clasificación" para consolidar cinco niveles:

1. **Detección:** el método ofrece una indicación cualitativa sobre la presencia de daño en la estructura.
2. **Localización:** el método ofrece información sobre la posible posición espacial del daño.
3. **Clasificación:** el método proporciona información sobre el tipo o modo de daño subyacente.
4. **Cuantificación:** el método entrega una estimación de la extensión o severidad del daño.
5. **Pronóstico (Prognosis):** el método estima la vida útil remanente (RUL, por sus siglas en inglés) o la capacidad de resistencia a futuro ante la evolución de la falla.

En esta jerarquización, los primeros cuatro niveles representan la etapa de diagnóstico, mientras que el quinto corresponde a la prognosis. Es importante señalar que esta jerarquía denota un grado de complejidad escalar; cada nivel requiere generalmente que el anterior se haya ejecutado de forma correcta (Figura 2.2).

Para abordar estos niveles, es fundamental definir la metodología mediante la cual se evalúa la respuesta de la estructura. La literatura contemporánea clasifica las estrategias de SHM en dos enfoques principales: SHM basado en modelos físicos (Model-Based) y basado en datos (Data-Driven).




Figura 2.1: Esquema de jerarquía de identificación de daño [3]

El enfoque basado en modelos depende de ecuaciones explícitas y simulaciones del modelo estructural para rastrear variaciones que identifiquen el daño. En este enfoque, el modelo funciona como una abstracción matemática capaz de conectar y correlacionar los parámetros de entrada y salida mediante las propiedades físicas del sistema. Entre los métodos numéricos establecidos se encuentran los Métodos de Diferencias Finitas (DFM), Métodos de Elementos de Frontera (BEM) y el Método de Elementos Finitos (FEM). Este último es el más utilizado debido a su capacidad paramétrica para modelar geometrías complejas, aunque resulta ser computacionalmente costoso o inviable ante la alta dimensionalidad de estructuras modernas.

Por otra parte, el enfoque basado en datos omite la necesidad de construir modelos matemáticos explícitos basados en la física. En su lugar, analiza los grandes volúmenes de respuestas recolectadas de la estructura mediante sensores para crear un modelo base de sus condiciones saludables, apoyándose en paradigmas de aprendizaje automático (Machine Learning) y reconocimiento de patrones. Este modelo permite que el sistema aprenda de los datos empíricos para identificar anomalías, clasificar los modos de falla y diagnosticar los daños de manera autónoma, resolviendo dependencias no lineales que los enfoques analíticos tradicionales no logran capturar con facilidad [27, 28].

2.1.1. Prognosis de daño

Como se estableció previamente, el concepto de daño estructural se centra en las alteraciones físicas que comprometen el desempeño funcional de un sistema de manera progresiva. Estos cambios suelen ser consecuencia de fenómenos de fatiga o corrosión de los materiales y pueden manifestarse de forma discreta – derivadas de la exposición a condiciones climáticas o de impactos operativos (vehículos civiles y militares)–, así como de manera continua a través del tiempo.

El Pronóstico de daño (*Damage Prognosis*, DP) se define formalmente como "la estimación de vida útil de un sistema" (Remaining Useful Life, RUL) [4]. Esta estimación se obtiene a partir de la integración de datos críticos obtenidos de modelos de predicción, tales como el monitoreo de uso, información sobre pruebas y mantenimiento previo, caracterización de las condiciones de operación y ambientales en sus diversas etapas: pasadas, presentes y anticipaciones sobre su comportamiento a futuro, entre otras. D

Si bien la implementación de DP varía según la aplicación específica, su estructura se fundamenta generalmente en tres pilares:

- Sistemas de instrumentación y hardware de procesamiento: Dispositivos encargados de la adquisición y tratamiento inicial de señales
- Interrogación de datos: Métodos de análisis y extracción de características relevantes sobre el estado del sistema.
- Modelo predictivo: Algoritmos o modelos físico-matemáticos orientados a la estimación del comportamiento futuro.




Figura 2.2: Esquema de estrategias de pronóstico de daño. Adoptado de [4]

2.2. Redes de sensores inalámbricas e internet de las cosas

Para la implementación efectiva de un sistema de SHM, la adquisición continua de datos exige infraestructuras de comunicación escalables e interconectadas. En este sentido, la evolución hacia el Internet de las Cosas (IoT) y las Redes de Sensores Inalámbricas ha proporcionado mecanismos dinámicos para el despliegue de estructuras inteligentes. Estas tecnologías de red ofrecen ventajas operativas sustanciales frente a las configuraciones tradicionales, destacando una instalación simplificada, reducción significativa de costos de cableado, alta confiabilidad y una gran robustez ante factores ambientales complejos. Al integrar elementos de detección con protocolos de comunicación de bajo consumo y largo alcance (como LoRa), se facilita la creación de ecosistemas descentralizados donde los datos físicos se capturan y comunican de manera ininterrumpida [29, 30].

El funcionamiento de estas plataformas se basa en la distribución de múltiples nodos sensores que actúan de manera coordinada para transmitir volúmenes masivos de información a bases de datos o unidades de procesamiento en la nube. Es precisamente en esta arquitectura descentralizada donde los modelos matemáticos y las técnicas de Inteligencia Artificial logran su máximo potencial. Al recibir un flujo constante de mediciones inalámbricas, los algoritmos de aprendizaje automático (Machine Learning) pueden ingerir la información para ejecutar tareas de reconocimiento de patrones, aislar el ruido ambiental y clasificar de forma autónoma cualquier indicio temprano de falla o anomalía estructural [29].

Las Redes de Sensores son infraestructuras que se componen de elementos de medición, cómputo y comunicación que permiten la instrumentación, observación y reacción a los eventos y fenómenos en un entorno especificado [?]. Por otra parte, Hill [31] define una Red de Sensores Inalámbrica (*Wireless Sensor Network, WSN*) como "un

conjunto de nodos organizados en una red cooperativa". En dicho sentido, se entiende que este tipo de redes

2.2.1. Topologías de Redes de Sensores Inalámbricas

De acuerdo a la forma en la que se conectan los sensores, las WSN se clasifican bajo las siguientes topologías:

- Estrella (Star)
- (Bus)
- Árbol (Tree)
- Malla(Mesh)

La topología de estrella es la más utilizada y se caracteriza por tener todos sus nodos conectados directamente al nodo de operación central. Esta configuración permite la linearización del flujo de datos y la reducción de latencia durante la transferencia de datos




Figura 2.3: Topología de Estrella en WSN [5]

El uso de WSN ha aumentado significativamente en las últimas décadas. Esto se debe principalmente a la fusión de áreas como el Internet de las cosas (IoT, por sus siglas en inglés), el cómputo en el borde (Edge Computing, EC) y el procesamiento de datos en tiempo real para el desarrollo de sistemas de monitoreo que ofrecen baja latencia y escalabilidad en la disposición de sensores de manera automática.

2.2.2. Aplicación de WSN en SHM con materiales compuestos

La integración de redes de sensores en materiales compuestos representa uno de los desarrollos más críticos para garantizar la seguridad en sectores de alta exigencia, tales como la industria aeroespacial y de energía eólica. Debido a las propiedades anisotrópicas inherentes a estos materiales y a la alta complejidad de las cargas mecánicas y térmicas a las que se someten, predecir analíticamente su degradación resulta extremadamente difícil. El despliegue de redes de sensores integradas o embebidas

(built-in sensor networks) dentro del propio material soluciona esta limitación al funcionar como un sistema de vigilancia intrínseco. Esta estrategia mejora la fiabilidad de las estructuras compuestas y reduce de manera importante sus costos de mantenimiento a lo largo del ciclo de vida útil (Qing et al., 2022).

En términos de aplicaciones prácticas, las plataformas sensoriales aplicadas a compuestos se combinan frecuentemente con técnicas avanzadas de fusión de datos y aprendizaje profundo para la cuantificación inteligente del daño. Por ejemplo, en el monitoreo de componentes aeroespaciales, se emplean redes de sensores piezoeléctricos para mediciones de ondas guiadas o sensores de fibra óptica (FBG) acoplados a infraestructuras IoT. Estas redes recopilan continuamente las respuestas dinámicas del material y las suministran a modelos de redes neuronales profundas (como CNN o arquitecturas recurrentes). Esto permite a los ingenieros detectar perturbaciones microestructurales invisibles en la superficie, clasificar fenómenos de delaminación o agrietamiento de la matriz polimérica, y predecir de forma precisa la distribución de la carga y la vida útil remanente del compuesto bajo condiciones reales de operación (Ogunleye, 2024; Qing et al., 2022).

2.3. Inteligencia Artificial

En el ámbito de las ciencias computacionales y la ingeniería, la Inteligencia Artificial (IA) actúa como el dominio principal del cual se derivan herramientas revolucionarias capaces de procesar información compleja. Dentro de este amplio campo, el Aprendizaje Automático (o Machine Learning, ML) se ha consolidado como una de las tecnologías más disruptivas. De acuerdo con Sharifani y Amini [32], el ML y el aprendizaje profundo son tecnologías revolucionarias en el campo de la IA que han ganado una inmensa popularidad debido a su capacidad inédita para hacer predicciones, analizar grandes conjuntos de datos y proporcionar conocimientos que antes eran imposibles de obtener mediante métodos tradicionales.

Desde una perspectiva técnica y conceptual, el Aprendizaje Automático se define como una tecnología que utiliza algoritmos para permitir a las computadoras analizar datos y procesar tareas estimulando la forma en que aprenden los humanos, lo que le permite mejorar continuamente su exactitud y capacidad por sí misma [33]. Para lograr esto, el ML engloba una variedad de modelos matemáticos que son entrenados de manera "no explícita", es decir, sin requerir instrucciones rígidas paso a paso, con el fin de realizar una tarea específica basándose en datos históricos [28]

El objetivo general de estas técnicas originadas en la Inteligencia Artificial es reconocer patrones y modelar regresiones en cantidades masivas de datos para resolver sistemas o problemas complejos de alta dimensionalidad [27]. En la actualidad, esta capacidad analítica asume un papel fundamental en el SHM, donde los algoritmos de aprendizaje automático se encargan de extraer información de las respuestas dinámicas de los materiales para clasificar automáticamente el estado de salud de la estructura y detectar anomalías.

2.3.1. Machine Learning

El aprendizaje automático, o Machine Learning (ML) se define de acuerdo a Mitchell [34] de la siguiente manera:

Se dice que un programa computacional aprende de la experiencia E con respecto a alguna clase de tareas T y un rendimiento P , si su rendimiento en tareas T , como es medido por P , mejora con la experiencia E .

Dicho de otra manera, ML involucra el desarrollo de algoritmos computacionales a través de la experiencia, facilitando el aprendizaje de las máquinas y optimizando su rendimiento en la realización de tareas sin la necesidad de ser explícitamente programadas. Dicha experiencia se obtiene de forma autónoma mediante el procesamiento de grandes conjuntos de datos mediante los cuales la máquina desarrolla modelos computacionales que le permiten resolver tareas o predecir condiciones a futuro.

De acuerdo a la forma en la que el entrenamiento de la máquina es supervisado, su aprendizaje suele clasificarse de la siguiente forma como supervisado, no supervisado, semi-supervisado, aprendizaje reforzado, etcétera. En el aprendizaje *supervisado*, la máquina procesa conjuntos de datos que han sido limpiados, ordenados y que además contienen las soluciones deseadas, denominadas comunmente como *etiquetas*.




Figura 2.4: Diagrama relacional de IA y ML

2.3.2. Random Forest

El algoritmo de Random Forest (RF) (Figura 2.5) es un método de ML supervisado basado en la técnica de aprendizaje en conjunto (ensemble learning), el cual opera construyendo una multitud de árboles de decisión de forma simultánea durante su fase de entrenamiento. Dicho algoritmo agrega y promedia las predicciones de múltiples árboles independientes para generar un resultado final mucho más robusto y preciso, en lugar de depender de un único modelo analítico [35] Esta arquitectura combinada

resulta vital para la evaluación estructural, ya que permite realizar tanto tareas de clasificación (identificar la severidad o el tipo de daño) como de regresión (cuantificar la reducción de rigidez o el tamaño de una grieta), mitigando significativamente el problema del sobreajuste (overfitting) que suele afectar a los árboles de decisión individuales.




Figura 2.5: Modelo Random Forest (adaptado de [6])

Una de las ventajas más destacadas de RF en el análisis de daño estructural es su capacidad innata para procesar conjuntos de datos complejos, no lineales y de alta dimensionalidad con un requerimiento mínimo de preprocesamiento. Adicionalmente, trabajos enfocados en la optimización de datos resaltan una de sus propiedades nativas más valiosas: la estimación de la "importancia de las variables" (feature importance). Dicha métrica permite al modelo evaluar el peso y la contribución real de cada característica extraída de las señales de los sensores, tales como el tiempo de vuelo, métricas estadísticas o coeficientes de frecuencia, actuando como un filtro eficaz que elimina el ruido o la redundancia en los datos antes de emitir un diagnóstico.

En el ámbito específico del SHM y la evaluación de materiales compuestos, Random Forest ha demostrado consistentemente un rendimiento sobresaliente. Estudios recientes abarcados en la literatura (como los de Amini y Rahmani y Dabetwar et al.) evidencian que este algoritmo es altamente eficaz para clasificar la acumulación de daño por fatiga y delaminaciones ocultas utilizando señales acústo-ultrasónicas u ondas de Lamb. Gracias a su excelente equilibrio entre un alto poder predictivo, gran facilidad de interpretación de resultados y un costo computacional considerablemente menor al de las complejas redes neuronales profundas (Deep Learning), el Random Forest se posiciona como un modelo de referencia clásico y confiable para la detección y el diagnóstico de integridad estructural.

2.3.3. Random Forest aplicado al monitoreo de salud estructural

Como se mencionó anteriormente, el algoritmo RF tiene la capacidad de modelar relaciones no lineales y procesar datos de alta dimensionalidad. Esto ha impulsado su aplicación en las diversas etapas del SHM. En la fase de diagnóstico, que abarca tanto la detección como la clasificación de daño, la literatura evidencia su eficacia operativa. Por ejemplo, Amini y Rahmani [36] emplearon este modelo para categorizar distintos niveles de daño por fatiga en polímeros reforzados con fibra de carbono (CFRP), utilizando como características diversas señales ultrasónicas derivadas de ondas de Lamb.

Por otro lado, la etapa de detección de daño se ha abordado desde enfoques complementarios para resolver desafíos inherentes a la adquisición física de los datos. Zhou [37] examina cómo mitigar el alto costo computacional y la redundancia de información generada por las redes de sensores, proponiendo la extracción de características mediante paquetes wavelet antes de clasificar la información estructural. En un enfoque paralelo, estudios como el de Debetwar [38] se centran en el diagnóstico directo y preciso del daño acumulado por fatiga, evaluando también especímenes de CFRP.

Asimismo, el alcance de este algoritmo se extiende a la etapa de pronóstico, un área crítica para la estimación de la vida útil remanente de los materiales. Al respecto, Liu et al. [39] desarrollaron un enfoque basado en datos para cuantificar con precisión el área de delaminación en materiales compuestos laminados. Su metodología logra establecer una correlación directa entre los cambios en la propagación de ondas y la geometría específica del defecto, facilitando el seguimiento de la progresión de la falla.

De este modo, la literatura demuestra que Random Forest supera la mera detección y clasificación de anomalías físicas. Su capacidad para gestionar la incertidumbre y procesar variables complejas lo consolida como una herramienta robusta y multidimensional, apta tanto para el diagnóstico inmediato en sistemas SHM como para la predicción evolutiva del daño estructural.

2.3.4. Redes Neuronales Profundas

Las redes neuronales profundas (DNN, por sus siglas en inglés) constituyen una subcategoría avanzada de la inteligencia artificial inspirada en la estructura y el comportamiento interconectado del cerebro humano [32]. Su arquitectura fundamental se compone de una capa de entrada que recibe las variables del entorno, una capa de salida que emite las predicciones o clasificaciones finales, y una secuencia de múltiples niveles intermedios conocidos como capas ocultas. Dentro de estos niveles, unidades de procesamiento individuales denominadas neuronas artificiales se vinculan mediante conexiones numéricas parametrizadas por pesos y sesgos [40]. Mediante la aplicación secuencial de funciones de activación no lineales, cada capa oculta transforma matemáticamente la información recibida [40], lo que dota a la red de una capacidad sobresaliente para aproximar y resolver problemas matemáticos de extrema compleji-

dad que los modelos lineales o estadísticos tradicionales no pueden abordar de forma directa.

En el contexto de la ingeniería y el monitoreo de integridad estructural, la profundidad de estas redes es precisamente lo que les permite gestionar la alta dimensionalidad, el ruido aleatorio y las variaciones ambientales de las lecturas de los sensores [41, 42]. A medida que los datos crudos, como las señales de aceleración, vibración o respuestas dinámicas transitorias, se propagan a través de la estructura jerárquica de la red, las capas iniciales capturan componentes o patrones de baja frecuencia, mientras que las capas más profundas combinan recursivamente dicha información para estructurar abstracciones complejas [43]. Este procesamiento matemático multinivel permite mapear fenómenos altamente no lineales, tales como la degradación interna de los materiales, la presencia de delaminaciones ocultas o las reducciones localizadas de rigidez mecánica ante sollicitaciones dinámicas severas [35, 43]. Esta notable aptitud para asimilar representaciones complejas de manera autónoma es el cimiento técnico sobre el cual se erige el paradigma del aprendizaje profundo.

2.4. Deep Learning

El término Deep Learning (DL) se emplea para hacer referencia a la subrama de ML capaz de trabajar con grandes cantidades de información [44] y que engloba el ajuste de DNNs a dicha información [45]. Este tipo de aprendizaje representa la evolución metodológica de las redes neuronales cuando estas se configuran y entrenan con algoritmos optimizados para explotar masivamente grandes volúmenes de datos. La principal ventaja competitiva del DL frente al ML convencional radica en eliminar la necesidad de realizar una extracción manual de características [38, 46]. En el enfoque clásico, un experto humano debe preprocesar las señales para aislar indicadores estadísticos específicos en el dominio del tiempo o de la frecuencia antes de alimentar un clasificador [37, 47]. El aprendizaje profundo altera radicalmente este flujo de trabajo, puesto que la propia arquitectura multinivel de la red es capaz de aprender simultáneamente tanto los descriptores de condición más relevantes como el mapeo predictivo final, reduciendo la incertidumbre introducida por el sesgo humano durante la ingeniería de variables [46].

Existe una amplia variedad de aplicaciones para este subgrupo de modelos. Sin embargo, dentro de las más comunes se encuentran las siguientes:

- Procesamiento de Lenguaje Natural (*Natural Language Processing*, NLP)
- Visión Computacional (*Computer Vision*, CV)
- Reconocimiento del habla (*Speech Recognition*, SR)
- *Monitoreo de Salud Estructural*

Para explotar las capacidades en el SHM de componentes y materiales compuestos, el aprendizaje profundo se despliega a través de diversas variantes arquitectónicas adap-

tadas a la naturaleza física del problema. Por un lado, las Redes Neuronales Convolucionales (CNN) se consolidan como herramientas dominantes cuando el diagnóstico se basa en información espacial o imágenes digitalizadas, siendo capaces de automatizar la localización y cuantificación de fallas mediante filtros automáticos [41, 48]. Por otro lado, cuando el análisis demanda procesar series temporales dinámicas o respuestas a largo plazo bajo condiciones ambientales cambiantes, las Redes Neuronales Recurrentes (RNN) y sus variantes de memoria de largo y corto plazo (LSTM) se tornan indispensables [49]. Sus bucles de retroalimentación interna les confieren la propiedad de retener información de estados pasados, permitiendo evaluar el comportamiento histórico de la estructura y estimar con mayor precisión la vida útil remanente (prognosis) [50], como veremos a continuación.

2.5. Redes Neuronales Recurrentes

Las Redes Neuronales Recurrentes (RNN, por sus siglas en inglés) presentan una gran ventaja frente a arquitecturas de propagación hacia adelante (*feed-forward*) más simples debido a su capacidad de actualización del estado interno a partir de etapas previas y de los datos de entrada actuales. Tal como señalan autores clásicos en la prognosis basada en datos [50], estas redes contienen conexiones de retroalimentación desde las capas ocultas o de salida hacia las capas precedentes, lo cual dota a la arquitectura de cierto tipo de “memoria” interna. Mediante esta característica, pueden procesar información dinámica y datos puramente secuenciales, tales como series de tiempo de vibración, emisiones acústicas o respuestas transitorias en la evaluación de la integridad estructural.

La arquitectura de una RNN básica (Figura 2.6) se compone de tres vectores principales: un **vector de entrada** (x_t), el cual contiene la información más reciente extraída de los sensores, un **vector de estado oculto** (h_t) y un **vector de salida** (y_t), cada uno de ellos operando en el paso de tiempo t . En particular, h_t contiene información sobre los elementos y alteraciones previas en la secuencia de datos y depende, junto con y_t , del estado oculto anterior (h_{t-1}). A su vez, este último depende de un vector de entrada anterior (x_{t-1}) y del estado oculto previo (h_{t-2}), lo cual garantiza la retención temporal de la cinemática de la estructura en cada etapa.




Figura 2.6: Red Neuronal Recurrente en su forma más básica.

Las ecuaciones que definen esta arquitectura se presentan a continuación

$$h_t = f(W_{hh}h_{t-1} + W_{hx}x_t + b_h) \quad (2.1)$$

$$y_t = f(W_{yh}h_t + b_y) \quad (2.2)$$

donde f representa a la *función de activación*, la cual garantiza la correcta propagación de los datos. Adicionalmente, W_{hh} , W_{hx} y W_{yh} representan matrices de ponderación

El uso de RNN simples representa una gran ventaja en tareas de prognosis, reconocimiento de daño y predicción de series temporales, pero su desempeño se ve fuertemente limitado en secuencias muy largas debido al problema de desvanecimiento o explosión del gradiente [51], el cual impide el registro de dependencias a largo plazo en la información. Ante dicha desventaja, se han introducido variantes más robustas para capturar el historial de degradación del material.

2.5.1. Long Short-Term Memory

Las redes de Memoria a Corto y Largo Plazo (LSTM, por sus siglas en inglés) representan una arquitectura avanzada de aprendizaje profundo perteneciente a la familia de las redes neuronales recurrentes (RNN). Fueron introducidas originalmente por Hochreiter y Schmidhuber [52] con el propósito principal de resolver el problema del desvanecimiento del gradiente (vanishing gradient) el cual afecta el entrenamiento de las RNN convencionales al procesar secuencias largas [53]. Gracias a este diseño, los modelos LSTM son capaces de aprender a almacenar y correlacionar información a lo largo de intervalos de tiempo muy extensos, superando con facilidad miles de pasos de tiempo discretos, lo que optimiza significativamente el análisis de series temporales y datos secuenciales.

El éxito funcional de las redes LSTM radica en su particular arquitectura interna, la cual incorpora "células de memoria" reguladas por un sistema de compuertas multiplicativas (usualmente compuertas de entrada, salida y olvido). Estas compuertas aprenden a abrir o cerrar el acceso al flujo de información constante, permitiendo que la red determine de manera autónoma y adaptativa cuánta información del historial de la secuencia debe conservarse u olvidarse, y qué proporción de los datos provenientes de las mediciones actuales debe añadirse [49]. Esta capacidad de retención y actualización selectiva convierte a la arquitectura en una herramienta altamente eficiente para procesar datos dinámicos, superando a las redes recurrentes simples al no perder el contexto histórico.

En el campo del SHM y el estudio de materiales compuestos, los modelos LSTM han demostrado una superioridad notable frente a los enfoques estáticos tradicionales. Debido a que los mecanismos de daño estructural son procesos acumulativos dependientes del tiempo, las propiedades de memoria de las redes LSTM resultan fundamentales para evaluar el comportamiento histórico del material. Su implementación permite modelar con alta precisión las dependencias temporales de las señales para estimar la vida útil remanente (RUL) y predecir estados futuros [54]. Además, logran aislar de forma eficiente los efectos ambientales, como las variaciones térmicas estacionales, de

los cambios físicos reales causados por daño o impacto en las estructuras aeroespaciales [43].




Figura 2.7: Diagrama básico de función de transmisión unitaria de LSTM

2.5.2. Gated Recurrent Unit

La Unidad Recurrente Cerrada (Gated Recurrent Unit, GRU) es una de las variantes de LSTM más conocidas. Esta arquitectura fue introducida en 2014 por Cho et al. [55] y se caracteriza por presentar un funcionamiento similar al de LSTM con un número reducido de estados estado de actualización o *update* (z_t) y estado de reestablecimiento o *reset* (r_t). El estado de actualización equivale a la fusión de los estados de entrada y olvido en LSTM. Este estado determina qué elementos previos se descartan y qué elementos nuevos se añaden. El estado de reestablecimiento, por su parte, determina cuánta información debe olvidarse. Esta reducción de compuertas permite un procesamiento más rápido de la información, pero menos potente que LSTM

Las ecuaciones matemáticas de este algoritmo son las siguientes:

$$z_t = \sigma(W_{zx}x_t + W_{zh}h_{t-1} + b_z) \quad (2.3)$$

$$r_t = \sigma(W_{rx}x_t + W_{rh}h_{t-1} + b_r) \quad (2.4)$$

$$\tilde{h}_t = \tanh(W_{hx}x_t + W_{hr}(r_t \odot h_{t-1}) + b_h) \quad (2.5)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (2.6)$$

Donde 2.3 y 2.4 representan respectivamente el *vector update* y el *vector reset*. Dentro de las arquitecturas más recientes de RNN se encuentra la Unidad Recurrente Cerrada (*Gated Recurrent Unit, GRU*). Creada en 2014 [Chung et. al., 2014] como una alternativa al uso de LSTM, esta RNN se caracteriza por su reducido número de estados con respecto a LSTM: Un estado de Actualización (Update, z_t) y Estado de Reestablecimiento (Reset, r_t).




Figura 2.8: Diagrama básico de función de transmisión unitaria de GRU

2.5.2.1. Funciones de activación

Las funciones de activación desempeñan un papel fundamental en la arquitectura de las redes neuronales profundas, ya que son las encargadas de introducir la no linealidad matemática necesaria para que el modelo pueda aprender patrones complejos a partir de los datos. En el contexto de modelos recurrentes como las redes LSTM y GRU, la función sigmoide (σ) (Figura 2.9) es esencial para el mecanismo de control de las compuertas (tales como las de entrada, olvido y actualización). Esta función matemática transforma cualquier valor de entrada en un rango continuo estrictamente acotado entre 0 y 1. Este comportamiento es ideal para actuar como un filtro probabilístico de memoria: un valor de salida cercano a 0 indica que la característica es irrelevante y debe ser "olvidada" o bloqueada, mientras que un valor tendiente a 1 permite que la información relevante pase al siguiente paso de tiempo y modifique el estado de la célula [5, 35].




Figura 2.9: Funciones de activación tanh y sigmoide. Adoptado de [7]

Por otro lado, la función tangente hiperbólica ($\tanh$) (Figura 2.9), opera en estrecha

colaboración con la sigmoide dentro de estas mismas células de memoria, pero cumpliendo un propósito distinto. A diferencia de la función sigmoide, la $\tanh$ comprime los valores de entrada y los proyecta en un rango que va de -1 a 1. Al estar centrada en cero, esta función permite a la red neuronal procesar tanto incrementos (valores positivos) como decrementos (valores negativos) en el estado de la información, lo que facilita una convergencia más rápida y estable durante el entrenamiento continuo. En las ecuaciones características de estas arquitecturas, la tangente hiperbólica se emplea para generar los nuevos vectores de estado candidato (como $\tilde{h}_t$) que contienen la nueva información extraída de las mediciones actuales, la cual será escalada por la salida de las compuertas sigmoides antes de actualizar el historial del modelo [39,55].

2.6. Materiales Compuestos

El constante avance tecnológico en diversas áreas de la ingeniería ha incrementado la demanda de materiales de bajo peso, alta resistencia y rentabilidad para el desarrollo de nuevas infraestructuras y aplicaciones avanzadas. En este contexto, los materiales compuestos han ganado protagonismo debido a sus propiedades mecánicas superiores, entre las cuales destaca una mayor rigidez, así como una excelente tolerancia a la corrosión y al desgaste.

Los materiales compuestos se definen en la ingeniería moderna como aquellos sistemas formados por la combinación macroscópica de dos o más materiales constituyentes con propiedades físicas, mecánicas o químicas significativamente distintas. Típicamente, están integrados por una fase de refuerzo (como fibras de carbono, vidrio o aramida) que aporta resistencia y rigidez, y una fase matriz (como resina u otro tipo de polímeros) que encapsula, protege y transfiere las cargas a las fibras. Esta sinergia produce un material final con características superiores a las de sus componentes individuales, destacando su alta relación resistencia-peso, tolerancia a la fatiga y resistencia a la corrosión.

Debido a estas propiedades excepcionales, los compuestos se han vuelto indispensables en sectores de alta exigencia, tales como la industria aeroespacial, la infraestructura civil y la generación de energía eólica. Sin embargo, su naturaleza heterogénea y su comportamiento anisotrópico los hacen susceptibles a modos de falla complejos. A diferencia de los metales isotrópicos, donde las grietas suelen ser superficiales y visibles, los daños en los compuestos a menudo ocurren a nivel interno sin advertencias visuales, manifestándose como delaminaciones (separación de capas), agrietamiento de la matriz polimérica o rotura interna de las fibras [43,56].

2.6.1. Monitoreo de salud estructural en compuestos

A pesar de sus notables ventajas, las estructuras fabricadas con estos materiales son susceptibles a sufrir daños a lo largo de su vida útil. Los mecanismos de falla, tales como la delaminación, fatiga, los impactos o las microfisuras en la matriz, suelen iniciarse

a una escala microscópica o en el interior del laminado, lo cual complica enormemente su detección mediante inspecciones visuales tradicionales. Si estos defectos no se identifican oportunamente, la propagación del daño reduce drásticamente el rendimiento estructural y puede culminar en la fractura total y catastrófica del componente.

Precisamente debido a la complejidad de sus modos de falla y a la naturaleza "invisible" de sus defectos internos, la evaluación de la integridad de los materiales compuestos representa un desafío mayúsculo para los métodos de inspección no destructiva (NDT) tradicionales. Es en este contexto donde el Monitoreo de Salud Estructural (SHM) adquiere una relevancia crítica. Al integrar redes de sensores directamente en la estructura o embeberlos dentro de las capas del laminado, el SHM permite una vigilancia continua e intrínseca del material a lo largo de su ciclo de vida operativo, funcionando como un sistema nervioso artificial.

En la práctica, el estudio de compuestos mediante SHM emplea técnicas de detección tanto pasivas como activas. Destacan el uso de sensores piezoeléctricos (PZT) para la emisión y recepción de ondas ultrasónicas (como las ondas de Lamb), redes de fibra óptica (FBG) para la medición de deformaciones distribuidas, y el monitoreo de Emisión Acústica (AE), que capta las ondas transitorias de alta frecuencia generadas cuando el material sufre microfisuras. Estas plataformas sensoriales generan enormes volúmenes de datos que contienen la "huella digital" del estado de salud del material. No obstante, predecir analíticamente la degradación de un compuesto a partir de estos datos es sumamente difícil a través de enfoques puramente basados en la física y ecuaciones diferenciales, debido a las complejas interacciones de las cargas mecánicas y los ruidos térmicos ambientales [36, 43].

La creciente demanda de estos materiales ha impulsado su adopción en sectores como la industria automotriz, aeroespacial y infraestructura civil. Constituyen una alternativa superior frente a materiales monolíticos tradicionales tales como los metales y cerámicos debido a su relación resistencia-peso, su comportamiento térmico y su adaptabilidad de manufactura [57]. En particular, los materiales compuestos reforzados con fibra de carbono destacan por sus excelentes propiedades estructurales en relación con su ligereza.

2.6.2. Modelos de inteligencia artificial y machine learning en compuestos

La IA y, en particular, el aprendizaje automático se han posicionado como la solución predominante en el procesamiento eficiente de las señales recolectadas por los sistemas SHM. Los métodos basados en datos han demostrado ser altamente efectivos para el diagnóstico de daños en compuestos porque omiten la necesidad de modelar explícitamente las intrincadas leyes físicas de la estructura. En su lugar, los algoritmos de ML ingieren las señales empíricas de los sensores y aprenden automáticamente a extraer características no lineales, correlacionando las respuestas dinámicas con los diferentes estados de salud estructural [58, 59].

En dicho contexto, se han implementado con éxito tanto arquitecturas clásicas como profundas. Por un lado, modelos supervisados y de ensamble como Random Forest (RF) y Máquinas de Vectores de Soporte (SVM) son ampliamente utilizados para clasificar los niveles o tipos de daño, operando sobre características estadísticas previamente extraídas del dominio del tiempo o la frecuencia de las señales acústicas. Por otro lado, enfoques de Aprendizaje Profundo (Deep Learning), como las Redes Neuronales Convolucionales (CNN) o recurrentes, permiten ingerir datos crudos para localizar delaminaciones o estimar de forma autónoma la vida útil remanente (RUL), logrando aislar las variaciones ambientales del daño real en el compuesto [1].

Diversos proyectos de investigación han validado la sinergia operativa entre el SHM, los materiales compuestos y el Machine Learning. Por ejemplo, Califano et al. [56] desarrollaron un método de SHM pasivo que emplea Redes Neuronales Artificiales (ANN) entrenadas con distribuciones de deformación in situ para identificar con precisión la "huella digital" de placas compuestas de fibra de carbono/epoxi. Este modelo detecta anomalías basándose únicamente en los cambios de distribución de tensiones, de manera independiente a las condiciones de carga.

Asimismo, en estudios centrados en daños por fatiga, Amini y Rahmani (2023) aplicaron un proceso analítico utilizando Random Forest y métodos de clasificación de vecinos cercanos para evaluar y cuantificar los estados de deterioro en polímeros reforzados con fibra de carbono, procesando para ello señales acústico-ultrasónicas complejas. Investigaciones precursoras como la de Dabetwar et al. (2019) también han demostrado la superioridad de los métodos data-driven para la clasificación automática de cargas y fallos en placas laminadas, consolidando estas metodologías algorítmicas como el estándar moderno para la preservación de infraestructuras críticas compuestas.

2.6.3. Nanotubos de Carbono

Los nanotubos de carbono (Carbon Nanotubes, CNT) son nanomateriales formados a partir de láminas de grafeno de escala nanométrica enrolladas en forma cilíndrica. Este material fue reportado en 1991 por Iijima [60] quien lo observó en el hollín del carbono al recrear el experimento de evaporación por arco de descarga de Krätschmer-Huffman [61]. De acuerdo con el número de cilindros concéntricos que componen su estructura, los CNTs se clasifican principalmente en dos tipos: de pared simple (Single-Walled Carbon Nanotubes, SWCNT) cuando están formados por un solo cilindro, y de pared múltiple (Multi-Walled Carbon Nanotubes, MWCNT) cuando se componen de dos o más cilindros coaxiales. Cabe destacar que las estructuras reportadas por Iijima en 1991 fueron los MWCNT. Posteriormente, en 1993 Iijima *et al.* [62] descubrieron los SWCNT.

Dependiendo de su quiralidad (es decir, la orientación de la red hexagonal respecto al eje del tubo), este material puede exhibir comportamiento metálico o semiconductor. Además, sus propiedades eléctricas, tales como la conductividad, resistividad y capacitancia, pueden ser ajustadas o alteradas mediante la adición de ciertos grupos

químicos a través de procesos de funcionalización o dopaje. Esta versatilidad hace de los CNT un material de alta relevancia en el área de la electrónica, ofreciendo diversas aplicaciones en este campo de la ingeniería. Actualmente, los CNT se utilizan principalmente para almacenamiento de datos, así como aplicaciones de biosensado y de baterías de ion-litio.

2.6.4. Nanotubos de Carbono en Monitoreo de Salud Estructural

Debido a factores tales como su alta conductividad y a sus excepcionales propiedades mecánicas, los CNT han generado gran interés en el diseño de sistemas de monitoreo para estructuras. Una de las aplicaciones más destacadas es su implementación en la creación de sensores a partir de materiales compuestos basados en CNTs [63]. La incorporación de CNTs en estos compuestos mejora significativamente su red conductora, haciéndolos altamente sensibles a las deformaciones mecánicas a través del efecto piezorresistivo. Esta característica permite correlacionar los cambios en la resistividad eléctrica con el estado de daño o tensión del material, convirtiéndolo en un excelente medio de autosensado [64].

Capítulo 3

Prognosis en compuestos con fibras de vidrio modificadas con nanotubos de carbono

En esta sección se detalla el marco metodológico diseñado para la construcción, entrenamiento y evaluación del programa de modelado computacional. A continuación, se presenta de manera cronológica el flujo de trabajo implementado, el cual abarca desde la preparación inicial de los datos hasta la configuración algorítmica de las redes neuronales, garantizando la replicabilidad y el rigor técnico del presente estudio.

3.1. Importancia de prognosis con inteligencia artificial y redes de sensores inalámbricas

La integración de WSNs en los sistemas de SHM ha revolucionado la capacidad de recopilar datos continuos y en tiempo real sobre el comportamiento dinámico de las infraestructuras. Sin embargo, esta transición tecnológica genera volúmenes masivos de datos complejos, ruidosos y altamente dimensionales que superan las capacidades de los enfoques matemáticos y físicos convencionales. En este escenario, la implementación de arquitecturas y modelos de IA y ML respectivamente, resultan indispensables para posibilitar la interpretación de dicha información. Al actuar como núcleo analítico del sistema, las redes neuronales pueden procesar de forma autónoma las señales transmitidas por los múltiples nodos de la red inalámbrica, filtrando las interferencias ambientales y extrayendo automáticamente las características no lineales que representan el estado de salud real de los materiales.

Más allá del diagnóstico de anomalías presentes, el verdadero valor estratégico de acoplar la IA con las plataformas WSN radica en su capacidad para ejecutar una prognosis precisa y confiable. Las arquitecturas algorítmicas, especialmente aquellas de aprendizaje profundo diseñadas para series temporales, logran identificar y modelar las trayectorias de degradación a partir del flujo ininterrumpido de mediciones inalám-

bricas. Esta sinergia predictiva permite anticipar modos de falla antes de que estos alcancen niveles críticos de propagación, facilitando una transición definitiva desde el mantenimiento reactivo hacia estrategias de gestión proactivas basadas en la condición real, lo que garantiza la seguridad operativa y optimiza los costos a lo largo de todo el ciclo de vida estructural.

3.2. Prognosis en fibras de vidrio modificadas con nanotubos de carbono con machine learning

El diseño y desarrollo del programa de modelado computacional basado en arquitecturas de Redes Neuronales Recurrentes (RNN), específicamente de LSTM y GRU, se estructuró en cuatro fases secuenciales interconectadas. En primer lugar, se llevó a cabo la caracterización del conjunto de datos, identificando las variables críticas, su distribución y las dependencias temporales inherentes. Posteriormente, se implementó una etapa rigurosa de preprocesamiento, orientada a la limpieza, normalización y estructuración de los datos en ventanas temporales aptas para modelos de aprendizaje profundo. Una vez consolidados los datos, se procedió a la fase de programación y construcción del programa de entrenamiento, utilizando la biblioteca Scikit-learn para ejecutar las tareas de partición de datos (entrenamiento/prueba), el escalado de características y la evaluación del rendimiento mediante métricas estadísticas estandarizadas, garantizando así la robustez y capacidad de generalización del sistema desarrollado. Finalmente se integró la biblioteca TensorFlow/Keras para la definición, compilación y entrenamiento de las capas LSTM y GRU.

3.3. Análisis y caracterización de las muestras

El esquema simplificado de caracterización y procesamiento de las señales obtenidas del espécimen, se muestran en la Figura 3.1. Como se puede visualizar en el diagrama, antes de comenzar con el diseño del programa de modelado, se requirió abordar diferentes etapas, desde la obtención de las muestras, pasando por el cálculo de hasta la clasificación del daño identificado en las mismas.




Figura 3.1: Diagrama de flujo del procesamiento de datos para predicción de daño. Adaptado de [8]

El conjunto de datos (en adelante, denominado como dataset) utilizado para entrenar los modelos se generó a partir de una fase experimental de ensayos destructivos. La

caracterización mecánica se rigió por la norma ASTM D7264, el procedimiento estándar para evaluar las propiedades a flexión, como la resistencia y la rigidez, en materiales compuestos. Los especímenes ensayados consistieron en paneles laminados de fibra de vidrio modificada con nanotubos de carbono, cuya provisión y adecuación fueron posibles gracias a la colaboración del Centro de Investigación Científica de Yucatán (CICY).

Geométricamente, cada muestra se dimensionó con 112 mm de longitud y 25 mm de ancho, con un espesor aproximado de 7mm (Figura 3.2). Para la adquisición de datos, se instrumentó la superficie de los paneles con 21 electrodos conductivos en cada extremo. Estos contactos se fijaron empleando pintura eléctricamente conductiva a base de agua, con una separación uniforme de 2.5 mm entre ellos. Esta configuración instrumental aseguró la resolución necesaria para captar con precisión las variaciones resistivas de la red de nanotubos durante la deformación del material.




Figura 3.2: Análisis dimensional de una muestra de fibra de vidrio modificada con CNT

Posteriormente, se calculó el cambio fraccional de resistencia normalizado $\left(\frac{\Delta R}{R_0}\right)$. El procesamiento de los datos en bruto se ejecutó mediante el software Virtual Structural Health Monitoring Laboratory [9] (Figura 3.3). A partir de este procedimiento, se generó el conjunto de datos `CN-F-D-S2-dR-R0.csv`, el cual fue empleado para el entrenamiento posterior de los modelos de inteligencia artificial.




Figura 3.3: Software de procesamiento de datos de SHM [9]

Las pruebas físicas se ejecutaron en una máquina universal de ensayos Shimadzu AG-1 (Figura 3.4). Las muestras se sometieron a un arreglo de flexión a cuatro puntos bajo la aplicación de una carga monotónica cuasiestática. El equipo se configuró con una celda de carga de 20 kN y operó a una velocidad de desplazamiento del cabezal constante de 1 mm/min, garantizando así una inducción de esfuerzo y daño controlada a lo largo de todo el ensayo.




Figura 3.4: Maquina Universal Shimadzu AG-1 (superior) y diagrama de cargas monotónicas aplicadas (inferior)

3.3.1. Criterios de clasificación de daño

La progresión del daño en el material se clasificó en cuatro etapas fundamentales, cuyos criterios de categorización se detallan en la Tabla 3.1. Esta clasificación vincula la respuesta eléctrica de la red de nanotubos con la integridad estructural del laminado. La Clase I corresponde al estado base, reflejando únicamente la variabilidad natural (ruido) de la señal. La Clase II captura la respuesta piezorresistiva del material, indicando una deformación elástica sin alteraciones estructurales permanentes. Por su parte, la Clase III define el daño incipiente, etapa caracterizada por la aparición de microfisuras en la matriz, micro-pandeo y la ruptura individual de las fibras de carbono. Finalmente, la Clase IV representa el daño macroscópico, una fase crítica que describe la coalescencia de estas microfisuras, el desarrollo de delaminación y la falla masiva o continua de las fibras.

Clase	Identificador	Comportamiento resistivo	Mecanismos asociados
I	Ruido	$\left \frac{\Delta R}{R_0} \right < 1 \%$	Variabilidad natural sobre el tiempo.
II	Piezorresistividad	$1 \% \leq \left \frac{\Delta R}{R_0} \right < 10 \%$	Respuesta piezorresistiva del material
III	Daño incipiente	$10 \% \leq \left \frac{\Delta R}{R_0} \right < 25 \%$	Aparición de microfisuras en la matriz, pandeo de fibras, rompimiento individual de fibras.
IV	Daño macroscópico	$\left \frac{\Delta R}{R_0} \right \geq 25 \%$	Fusión de microfisuras en la matriz, delaminación, unión de fallo en fibras.

Cuadro 3.1: Criterios de clasificación de daño en compuestos con nanoestructuras de carbono [8]

3.4. Machine Learning / Deep Learning

3.4.1. Modelado secuencial mediante redes neuronales recurrentes avanzadas

Para la modelación de fenómenos dependientes del tiempo, las Redes Neuronales Recurrentes (RNN) convencionales presentan limitaciones severas durante el proceso de optimización mediante retro propagación a través del tiempo (*Backpropagation Through Time*). Específicamente, el cálculo iterativo de gradientes sobre secuencias extensas induce al fenómeno del desvanecimiento o explosión del gradiente, donde la

información de los pasos de tiempo iniciales disminuye exponencialmente, impidiendo la captura de dependencias de largo plazo.

Para mitigar esta problemática, en esta investigación se implementaron y evaluaron dos variantes arquitectónicas basadas en mecanismos de compuertas: la red de Memoria a Corto y Largo Plazo (LSTM, Long Short-Term Memory) y la Unidad Recurrente Compuerta (GRU, Gated Recurrent Unit).

3.4.1.1. Arquitectura de Memoria a Corto y Largo Plazo

La arquitectura LSTM resuelve el desvanecimiento del gradiente introduciendo un estado de celda (c_t) que actúa como una autopista de información lineal, regulada por tres compuertas estocásticas interconectadas.

Para la implementación de las arquitecturas de aprendizaje profundo, se diseñó un flujo de trabajo híbrido que integra las librerías de Python, Scikit-learn y Tensorflow/Keras. Dicha integración permite trabajar las etapas de preparación y evaluación estadística de manera robusta con scikit-learn, aunada al alto rendimiento de Tensorflow para el cómputo tensorial y el entrenamiento de dichos modelos. La inclusión de ambas arquitecturas en el marco metodológico responde a la necesidad de contrastar empíricamente el balance entre la capacidad de abstracción de la LSTM (con un mayor número de parámetros libres) y la eficiencia computacional y velocidad de convergencia de la GRU.

3.4.2. Preparación y gestión del programa

Para la fase de modelado, se emplearon dos arquitecturas de Redes Neuronales Recurrentes: Long Short-Term Memory (LSTM) y Gated Recurrent Unit (GRU). Las redes neuronales se configuraron con una longitud de 10 steps, 1 capa oculta, 30 neuronas por capa y la tangente hiperbólica ($\tanh$) como función de activación. El conjunto de datos se dividió en una proporción del 75 % para entrenamiento (del cual se asignó un 20 % para validación) y 25 % para prueba, aplicando adicionalmente una validación cruzada de 30 iteraciones. El desempeño de los modelos se evaluó utilizando como métricas principales el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE).

3.4.3. Preprocesamiento y gestión de datos

Debido a la naturaleza de las funciones de activación presentes en las arquitecturas LSTM y GRU, las características del dataset fueron normalizadas para garantizar la estabilidad numérica durante el cálculo de gradientes. Se empleó el método de escalamiento *min-max* incluida en la biblioteca *Scikit-learn* a través de la función `MinMaxScaler` para transformar el espacio de características X al intervalo $[0,1]$ de

acuerdo a la siguiente ecuación:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Para capturar la dependencia temporal subyacente, el conjunto unidimensional fue reestructurado en tensores tridimensionales mediante la técnica de ventana temporal deslizante (sliding window). Se definió un tamaño de ventana de 10 pasos de tiempo, donde cada muestra de entrada x_i adquiere una dimensión (t, f) , siendo f el número de características, produciendo el valor objetivo y_{i+1}

3.4.4. Arquitectura del modelo secuencial

El núcleo predictivo del sistema fue diseñado utilizando la interfaz de *TensorFlow* y *Keras*. La arquitectura seleccionada se fundamentó en unidades de memoria a corto y largo plazo (LSTM / GRU), elegidas por su capacidad para mitigar el problema del desvanecimiento del gradiente en secuencias largas. La topología de la red consistió en una capa de entrada recurrente con N unidades ocultas. Para introducir regularización y penalizar la coadaptación de las neuronas, se implementó una capa de Dropout con una tasa de retención probabilística p . La salida del bloque recurrente fue proyectada hacia una capa densa (Fully Connected) de una sola neurona con función de activación lineal, adecuada para la tarea de regresión continua.

3.4.5. Protocolo de entrenamiento y optimización

El proceso de optimización de los pesos sinápticos se llevó a cabo utilizando el algoritmo de estimación de momentos adaptativos (ADAM). Este algoritmo se eligió por su eficiencia computacional, sus bajos requerimientos de memoria y su robustez empírica frente a gradientes dispersos (sparse gradients) o funciones objetivo no estacionarias; características frecuentemente presentes en el entrenamiento de arquitecturas de aprendizaje profundo. La función de costo minimizada durante el entrenamiento fue el error cuadrático medio (MSE), definido matemáticamente como:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Para prevenir el sobreajuste empírico, el entrenamiento iterativo sobre las épocas fue gobernado por un mecanismo de parada temprana (Early Stopping). Este protocolo monitoreó la función de pérdida en un subconjunto de validación (20 % de los datos), interrumpiendo el entrenamiento si la métrica no exhibía una reducción superior a un umbral ϵ durante un periodo de paciencia de k épocas consecutivas.

3.4.6. Evaluación del desempeño

Finalizado el entrenamiento, las inferencias del modelo sobre el conjunto de prueba (previamente aislado del proceso de optimización) fueron transformadas inversamente

a su escala fenomenológica original. Las métricas de desempeño final se calcularon mediante los módulos de evaluación de Scikit-learn, permitiendo cuantificar la desviación estocástica del modelo respecto a la varianza real del fenómeno estudiado.

3.4.7. Implementación Algorítmica del Sistema Predictivo

Para consolidar el flujo de procesamiento de datos, construcción de la arquitectura y evaluación del modelo, se estructuró un algoritmo general que describe la secuencia lógica de ejecución computacional. Como se detalla en la Figura 3.5, el proceso integra la transformación del espacio temporal y la optimización de los pesos sinápticos de la red recurrente.

```
1  Entrada: Conjunto de datos temporales D, tamaño de ventana temporal t,  
    hiperparametros (alfa, p, N)  
2  Salida: Métrica de desempeño RMSE, Modelo optimizado "M"  
3  
4  D_train, D_test <- DividirDatos(D, ratio=0.8)  
5  S <- AjustarEscalador(D_train)  
6  D'_train <- Transformar(D_train, S)  
7  D'_test <- Transformar(D_test, S)  
8  
9  X_train, Y_train <- GenerarVentanas(D'_train, t)  
10 X_test, Y_test <- GenerarVentanas(D'_test, t)  
11  
12 M <- InicializarModeloSecuencial()  
13 M.AgregarCapaRecurrente(unidades=N, input_shape=(t, características))  
14 M.AgregarCapaDropout(tasa=p)  
15 M.AgregarCapaDensa(unidades=1, activación=lineal)  
16  
17 M.Compilar(optimizador=Adam(tasa_aprendizaje=alfa), pérdida=MSE)  
18 E <- EarlyStopping(monitor=val_loss, paciencia=k)  
19  
20 M.Entrenar(X_train, Y_train, validación=(X_test, Y_test), callbacks=[E])  
21  
22 Y'_pred <- M.Predecir(X_test)  
23 Y_pred <- TransformaciónInversa(Y'_pred, S)  
24 Y_real <- TransformaciónInversa(Y_test, S)  
25  
26 RMSE <- CalcularRaizErrorCuadraticoMedio(Y_real, Y_pred)  
27 Retornar RMSE, M
```

Figura 3.5: Pseudocódigo de funcionamiento del programa de entrenamiento

En la estructura descrita, el operador S representa el objeto escalador (*min-max*) responsable de mantener los metadatos de los valores máximos y mínimos del conjunto de entrenamiento para evitar filtración de datos (data leakage) hacia el conjunto de

prueba. Los hiperparámetros introducidos al sistema consisten en la tasa de aprendizaje α , la probabilidad de retención del Dropout p , y el número de unidades ocultas en la capa recurrente N . Adicionalmente, el hiperparámetro k determina la tolerancia de épocas para el mecanismo de parada temprana, garantizando que el modelo final M retorne los pesos óptimos generalizables.

Capítulo 4

Resultados/Discusión

4.1. Prognosis con modelos de aprendizaje automático

En la presente sección se exponen los resultados de entrenamiento obtenidos mediante el modelo de aprendizaje automático Random Forest, a partir de los datos registrados en el espécimen **CN-F-D-S1**. Del conjunto total de 40 señales analizadas, se seleccionó el nodo 11-9' (Figura 4.4) como muestra representativas, dado que en dicho nodo se registró presencia de daño estructural, manifestado a través de las clases III y IV del esquema de clasificación utilizado (Figura).




Figura 4.1: Diagrama de señal representativa seleccionada en CN-F-D-S1.

Los resultados de entrenamiento obtenidos mediante el modelo de ML, Random Forest, se muestran en la presente sección. El modelo alcanzó valores de precisión notables en las clases mayoritarias (como se muestra en la Figura 4.2), registrando un 100 % para la Clase I (Ruido) y un 88 % para la Clase II (Piezorresistividad). No obstante, este comportamiento óptimo está directamente condicionado por la distribución del vector de soporte (support): de las 53 muestras totales del conjunto de prueba, el 83.02 % ($N = 44$) pertenece a la Clase I, el 13.21 % ($n = 7$) a la Clase II, mientras que las Clases III y IV (críticas para la identificación de daño estructural) apenas representan el 1.89 % ($n = 1$) cada una.

	precision	recall	f1-score	support
1	1.00	0.98	0.99	44
2	0.88	1.00	0.93	7
3	0.50	1.00	0.67	1
4	0.00	0.00	0.00	1
accuracy			0.96	53
macro avg	0.59	0.74	0.65	53
weighted avg	0.96	0.96	0.96	53

Figura 4.2: Métricas de evaluación de desempeño del modelo Random Forest

El severo desbalance se evidencia al analizar el promedio macro (macro avg) del F1-score, el cual desciende a un 65 %. Esta métrica revela el deficiente desempeño del algoritmo ante la escasez de datos en las Clases III y IV, confirmando un sesgo predictivo hacia los estados estructurales normales o de baja afectación.




Figura 4.3: Diagrama de señal representativa 11-9'

Este sesgo se corrobora de forma gráfica en la señal de clasificación del nodo 11-9' a lo largo del tiempo (Figura 4.3). Durante los primeros 175 segundos, el modelo sostiene una predicción lineal y estable en la Clase I. Al introducirse la transición hacia etapas de daño (pasados los 175s), la salida del modelo experimenta una alta volatilidad, oscilando abruptamente entre las distintas clases. Pese a la existencia real de condiciones correspondientes a las Clases III y IV en la señal sintética, la rigidez del clasificador Random Forest prioriza probabilísticamente las Clases I y II, impidiendo una prognosis continua y confiable de la degradación estructural.

4.2. Prognosis con arquitecturas de aprendizaje profundo

En la presente sección se exponen los resultados de entrenamiento, validación y predicción obtenidos mediante las arquitecturas LSTM y GRU, a partir de los datos registrados en el espécimen **CNT-D-S2**. Del conjunto total de 40 señales analizadas,

se seleccionaron las correspondientes a los nodos 08-10' y 10-12' (Figura 4.4) como muestras representativas, dado que en dichos nodos se registró presencia de daño estructural, manifestado a través de las clases III y IV del esquema de clasificación adoptado.




Figura 4.4: Diagrama de señales representativas seleccionadas en CNT-D-S2.

4.2.1. Prognosis con long-short term memory

4.2.1.1. Resultados de la señal 08-10'

En la Figura 4.5 se presentan las curvas de pérdida (Figura 4.5(a)) y de las métricas RMSE y MAE (Figuras 4.5(b) y 4.5(c), respectivamente), empleadas para evaluar la estabilidad del modelo durante la fase de entrenamiento correspondiente a la muestra 08-10'. Como se puede apreciar en las tres curvas, durante las primeras diez épocas se registra un descenso pronunciado seguido de un periodo de estabilización, lo cual evidencia una rápida convergencia del modelo tras dicho número de iteraciones. Asimismo, la ausencia de divergencia entre las curvas de entrenamiento y validación descarta la presencia de sobreajuste, lo que valida la capacidad de generalización del modelo frente a datos no observados durante el entrenamiento.




Figura 4.5: Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en 08-10' con LSTM

Estos resultados se corroboran de manera visual en la Figura 4.6, la cual presenta una comparativa entre los datos reales y los valores predichos durante la etapa de prueba. Tal como se señaló previamente, el modelo demuestra una alta capacidad de generalización, entendida como la aptitud para abstraer los patrones y relaciones subyacentes en los datos de entrenamiento y reproducirlos de manera equilibrada y consistente ante muestras no observadas.




Figura 4.6: Entrenamiento de modelo con arquitectura LSTM en 08-10'

Con el propósito de evaluar el rendimiento global de la arquitectura, se empleó la matriz de confusión presentada en la Figura 4.7. El modelo alcanzó una exactitud global del 80.6 %, exhibiendo una alta sensibilidad en las clases I y III (Tabla 4.3), así como un desempeño sólido en la clase IV, a pesar de que esta última contó con un número considerablemente menor de muestras en comparación con las demás clases. La clase II, por su parte, si bien registró una precisión superior a la de las clases I y III, presentó una alta dispersión en sus predicciones, lo que sugiere que el modelo identificó similitudes estadísticas entre los patrones de dicha clase y los de clases adyacentes, derivando en clasificaciones ambiguas.




Figura 4.7: Matriz de confusión con arquitectura LSTM en 08-10'

Clase	Precisión (%)	Sensibilidad (%)
I	92	100
II	100	35
III	36	100
IV	100	86

Cuadro 4.1: Métricas de desempeño de la arquitectura LSTM en la muestra 08-10'

Finalmente, en la Figura 4.8 se presentan los resultados de pronóstico ordenados en correspondencia con la señal original medida. En dicha figura es posible corroborar que los elevados porcentajes de precisión y sensibilidad registrados en las clases I y III son consistentes con la mayor representatividad estadística de sus muestras dentro del conjunto de entrenamiento. En contraste, la clase II evidencia una disponibilidad de muestras insuficiente para que el modelo logre establecer con claridad los límites de decisión entre dicha clase y la clase III, lo que se traduce en la ambigüedad clasificatoria previamente discutida. Estos resultados motivan el análisis del espécimen subsecuente, en el cual se examinará el comportamiento del modelo ante una distribución de datos distinta, con el propósito de valorar la robustez y consistencia de la arquitectura LSTM en diferentes condiciones de muestreo.




Figura 4.8: Resultados de Prognosis de daño con arquitectura LSTM en 08-10'

4.2.1.2. Resultados de la señal 10-12'

En la Figura 4.9 se presentan las curvas de las métricas empleadas para evaluar la estabilidad del modelo durante la fase de entrenamiento correspondiente a la señal 10-12'. De manera análoga al espécimen anterior, se registra un descenso pronunciado en la curva de pérdida (Figura 4.9(a)) y en las curvas de error (Figuras 4.9(b) y 4.9(c)) durante las primeras diez épocas, lo cual evidencia una rápida convergencia y estabilización del modelo tras dicho número de iteraciones. Asimismo, las curvas no

exhiben divergencia entre las fases de entrenamiento y validación, lo que confirma la ausencia de sobreajuste y respalda la capacidad de generalización del modelo. Cabe destacar que, en este caso, la brecha entre las curvas de MAE de entrenamiento y validación es considerablemente reducida, lo cual constituye un indicador de aprendizaje robusto y sugiere una adecuada transferencia de los patrones aprendidos hacia datos no observados durante el entrenamiento. Estos hallazgos se corroboran en la Figura 4.10, donde se presenta una comparativa entre los valores reales y los predichos durante la fase de prueba.




Figura 4.9: Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (10-12') con LSTM




Figura 4.10: Entrenamiento de modelo con arquitectura LSTM en 10-12'

Con el propósito de evaluar el rendimiento global de la arquitectura, se empleó la matriz de confusión presentada en la Figura 4.11. El modelo alcanzó una exactitud global del 93.5 %, exhibiendo una alta sensibilidad en la clase I (Tabla 4.4), así como un desempeño sólido en las clases II y III. Cabe señalar que no se registraron instancias pertenecientes a la clase IV en esta muestra, lo cual es consistente con las condiciones de daño presentes en el espécimen y puede corroborarse visualmente en la Figura 4.12, donde los resultados de pronóstico se presentan en correspondencia con la señal original medida.




Figura 4.11: Matriz de confusión con arquitectura LSTM en 10-12'

Clase	Precisión (%)	Sensibilidad (%)
I	94	100
II	89	94
III	83	100
IV	-	-

Cuadro 4.2: Métricas de desempeño de la arquitectura LSTM en la muestra 10-12'

En la Figura 4.12 se presentan los resultados de prognosis correspondientes a la señal 10-12', ordenados en correspondencia con la señal original medida. En dicha figura es posible corroborar los elevados porcentajes de precisión y sensibilidad reportados en las clases I, II y III, así como constatar la ausencia de instancias pertenecientes a la clase IV, en concordancia con lo discutido previamente. En conjunto, los resultados obtenidos para ambos especímenes con la arquitectura LSTM demuestran una capacidad de aprendizaje robusta y una adecuada generalización ante distintas condiciones de muestreo, sentando las bases para la evaluación comparativa con la arquitectura GRU que se desarrolla en la sección subsecuente.




Figura 4.12: Resultados de Prognosis de daño con arquitectura LSTM en 10-12'

4.2.2. Prognosis con gated recurrent unit

En la presente sección se exponen los resultados de prognosis obtenidos mediante el entrenamiento de la arquitectura GRU sobre los conjuntos de datos muestrales, con el propósito de evaluar su desempeño predictivo y establecer una comparativa sistemática frente a los resultados previamente obtenidos con la arquitectura LSTM.

4.2.2.1. Resultados en los nodos 08-10'

En la Figura 4.13 se presentan las curvas de pérdida (Figura 4.13(a)) y de error (Figuras 4.13(b) y 4.13(c)) empleadas para la validación del entrenamiento correspondiente al espécimen 08-10'. Dichas curvas exhiben un descenso pronunciado análogo al observado con la arquitectura LSTM; no obstante, las curvas de pérdida y de MAE presentan en este caso una trayectoria considerablemente más suave, lo cual sugiere una mejor adaptación del modelo a los patrones subyacentes de la muestra. Asimismo, las gráficas no evidencian la presencia de sobreajuste, lo que valida la capacidad de generalización del modelo frente a los patrones de comportamiento del material. Estos hallazgos se corroboran en la Figura 4.14, donde las predicciones obtenidas describen trayectorias más suaves en comparación con las generadas por el modelo LSTM (Figura 4.6).




Figura 4.13: Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (08-10') con GRU




Figura 4.14: Entrenamiento de modelo con arquitectura GRU en 08-10'

La matriz de confusión correspondiente a esta señal se presenta en la Figura 4.15. El modelo alcanzó una exactitud global del 82.2 %, registrándose además un incremento en la precisión de clasificación, respecto al modelo LSTM, en las clases I y III del 5 % y el 14 %, respectivamente (Tabla 4.3). Estos resultados evidencian una mejora en la capacidad discriminativa del clasificador para dichas clases, comportamiento que resulta consistente con el efecto de suavizado observado durante la fase de prueba. Asimismo, se registró un incremento del 36 % en la sensibilidad correspondiente a la clase II, lo cual refleja una mayor capacidad del modelo para identificar el comportamiento piezorresistivo del material y, en consecuencia, caracterizar con mayor precisión los patrones de respuesta inherentes al mismo. La clase IV exhibió un desempeño comparable al obtenido con el modelo LSTM.




Figura 4.15: Matriz de confusión con arquitectura GRU en 08-10'

Clase	Precisión (%)	Sensibilidad (%)
I	97	100
II	100	71
III	50	100
IV	100	86

Cuadro 4.3: Métricas de desempeño de la arquitectura GRU en la muestra 08-10'

Finalmente, en la Figura 4.16 se presentan los resultados de pronosis obtenidos durante las etapas de entrenamiento y prueba, ordenados y graficados en conjunto con la señal medida correspondiente al espécimen 08-10'. En dicha figura es posible apreciar la correspondencia entre las clases registradas en la matriz de confusión y los puntos de predicción generados durante el entrenamiento, lo cual permite verificar visualmente la coherencia entre las métricas de clasificación reportadas y el comportamiento real de la señal.




Figura 4.16: Resultados de Prognosis de daño con arquitectura GRU en 08-10'

4.2.2.2. Resultados de la señal 10-12'

En la presente sección se exponen los resultados de prognosis obtenidos mediante el entrenamiento de la arquitectura GRU sobre las señales correspondientes al espécimen CNT-D-S2. Con fines comparativos, se emplearon las mismas señales analizadas en la sección anterior, correspondientes a los nodos 08-10' y 10-12'. En la Figura 4.17 se presentan las curvas de las métricas de validación del modelo. De manera análoga a los resultados previamente reportados, se registra un descenso pronunciado en la curva de pérdida (Figura 4.17(a)) y en las curvas de error (Figuras 4.17(b) y 4.17(c)) durante las primeras diez épocas, lo cual evidencia una rápida convergencia y estabilización del modelo tras dicho número de iteraciones. Asimismo, la ausencia de divergencia entre las curvas de entrenamiento y validación confirma la inexistencia de sobreajuste y respalda la capacidad de generalización del modelo ante datos no observados durante el entrenamiento.




Figura 4.17: Métricas de pérdida (loss) (a), RMSE (b) y MAE (c) en (10-12') con GRU




Figura 4.18: Entrenamiento de modelo con arquitectura GRU en 10-12'

Para medir el desempeño de la arquitectura, se utilizó su matriz de confusión de esta medición se muestra en la figura 4.19. Se determinó una exactitud (accuracy) global del 95.1 % para todas las clases. Dicha matriz refleja una precisión del 100 % para la Clase I, un 94.12 % para la Clase II un del 83.3 % para la Clase III. Los resultados demuestran la precisión del modelo para predecir las clases de ruido asignadas.




Figura 4.19: Matriz de confusión con arquitectura GRU en 10-12'

A continuación se presentan en la Tabla 4.4 las métricas de precisión y sensibilidad, calculadas conforme a la información obtenida en la matriz previa. De acuerdo a los resultados obtenidos, el modelo logró clasificar de manera correcta un 94 % de los datos de la Clase II (piezorresistividad) y un 100 % de la Clase III (Daño Incipiente)

Clase	Precisión (%)	Sensibilidad (%)
I	100	100
II	94	100
III	100	92
IV	-	-

Cuadro 4.4: Métricas de desempeño de la arquitectura GRU en la muestra 10-12'

Finalmente, en la figura 4.20 se ordenaron y graficaron los resultados de pronosis obtenidos durante la etapa de entrenamiento/prueba junto con la señal medida en (10-12'). En ella se puede visualizar la correspondencia entre las clases registradas en la matriz de confusión y los datos de predicción obtenidos durante el entrenamiento.




Figura 4.20: Resultados de Prognosis de daño con arquitectura GRU en 10-12'

Los resultados del modelo Random Forest indicaron una capacidad predictiva limitada para capturar la varianza asociada al daño estructural. Si bien alcanzó métricas de precisión notables en la detección de ruido (Clase I: 100 %) y piezorresistividad (Clase II: 88 %), se determinó que este rendimiento estuvo sesgado por un marcado desbalance de clases en el conjunto de datos de muestras (N=53). Como consecuencia de este comportamiento conservador hacia las clases mayoritarias, el modelo no fue capaz de generalizar ni generar resultados concluyentes para la identificación del daño estructural.

Nota: Agregar objetivo principal y justificar que se cumplió

Desarrollar un sistema de modelado computacional basado en técnicas de Deep Learning para el pronóstico de daño estructural en materiales compuestos laminados con nanotubos de carbono, validado mediante datos experimentales de resistividad eléctrica.

En contraste, las redes LSTM y GRU demostraron una alta eficiencia en el proceso de optimización, alcanzando una convergencia y estabilización en aproximadamente 10 épocas. Dichas arquitecturas demostraron una notable robustez frente al ruido y no se vieron afectadas negativamente por la distribución de los datos de entrenamiento. La superposición casi exacta entre las curvas de pérdida de entrenamiento y validación confirmó la ausencia de sobreajuste (overfitting), demostrando que el modelo aprendió las dinámicas subyacentes del fenómeno en lugar de memorizar el ruido estocástico.

Capítulo 5

Conclusiones y recomendaciones

En la presente investigación se desarrolló una herramienta de software fundamentada en técnicas de Aprendizaje Profundo (Deep Learning), diseñada para la predicción y evaluación de daño estructural en materiales compuestos laminados reforzados con nanoestructuras de carbono. El análisis de los resultados demostró su capacidad para generar modelos de prognosis robustos a partir de los datos de muestreo del material procesado. Con base en la validación de estos sistemas predictivos, se establecen las siguientes conclusiones:

- Respecto a la muestra 10 – 12', el modelo GRU alcanzó un punto de estabilidad aproximadamente entre las épocas 10 y 12, lo cual valida su capacidad para extraer patrones temporales con un menor número de iteraciones de entrenamiento.
- Las curvas de pérdida de entrenamiento y validación no mostraron señales de divergencia en ninguna de las arquitecturas, lo cual indica una excelente capacidad de generalización y la ausencia de sobreajuste (overfitting).
- La arquitectura GRU presentó valores de error de validación de RMSE = 0.025 % y MAE = 0.015 %, superando al modelo LSTM, el cual obtuvo un RMSE = 0.040 % y un MAE = 0.025 %. Esto demuestra un mayor grado de precisión y ajuste a los datos por parte de la red GRU.
- Aunque ambos modelos mostraron converger a gran velocidad, la curva de aprendizaje del modelo GRU se estabilizó de manera más suave y directa frente a las oscilaciones presentadas por el modelo LSTM.
- El tiempo de entrenamiento global del modelo GRU ($244s \approx 4.07min$) fue ligeramente menor frente al modelo LSTM ($248s \approx 4.13min$). Al considerar que la celda GRU posee una arquitectura simplificada (3 compuertas) frente a la LSTM (4 compuertas), estos resultados resaltan su mayor eficiencia computacional.
- Los archivos de configuración generados para cada señal alcanzaron un tamaño de 69 kB, ajustándose perfectamente al margen de memoria necesario (20 - 500 kB) para su eventual implementación en dispositivos de recursos limitados (Edge Computing).

A partir de los resultados obtenidos y del análisis de la herramienta de software desarrollada, se exponen a continuación diversas recomendaciones. Estas directrices tienen como propósito guiar la optimización y escalabilidad del sistema propuesto, así como plantear nuevas líneas de investigación para futuros trabajos en esta área:

- Se sugiere evaluar el desempeño de los modelos entrenados mediante su despliegue físico. Esto abarca desde la implementación directa de los archivos de configuración en microcontroladores de bajo consumo (Edge Computing), hasta su ejecución en servidores alojados en la nube (Cloud Computing), integrados en redes inalámbricas de sensores para monitorear la latencia y el consumo energético en tiempo real.
- Se recomienda entrenar los modelos con datos provenientes de pruebas de fatiga cíclica, en lugar de limitarse a cargas monotónicas. Esto permitirá evaluar si la arquitectura GRU mantiene su superioridad predictiva y de estabilización a largo plazo ante perfiles de carga más complejos.
- Dado que los presentes resultados se obtuvieron mediante el entrenamiento individual de cada señal de referencia, se propone desarrollar un esquema de entrenamiento global. Para mitigar el impacto en el costo computacional, será indispensable emplear procesamiento acelerado por GPU, utilizando arquitecturas como CUDA.
- Resulta conveniente evaluar y comparar otras arquitecturas de redes neuronales artificiales (ANN) reportadas en la literatura para sistemas de monitoreo. A la par, se sugiere implementar técnicas de optimización automatizada de hiperparámetros para determinar si es posible reducir aún más los márgenes de error obtenidos en este trabajo.
- Se considera pertinente diseñar una interfaz gráfica de usuario (GUI) que centralice el flujo de trabajo, facilitando el entrenamiento, la visualización de las inferencias de daño estructural en tiempo real y la gestión de bases de datos y métricas en formatos estandarizados.

Como parte de la extensión de este trabajo, actualmente se encuentra en fase de redacción una serie de artículos de investigación derivados de este estudio. Estas futuras publicaciones están orientadas a profundizar en la validación experimental y en los aspectos metodológicos aquí expuestos, con el objetivo de someter los hallazgos a revisión por pares y contribuir a la literatura científica especializada en la materia.

Bibliografía

- [1] G. Scarselli and F. Nicassio, "Machine learning for structural health monitoring of aerospace structures: A review," Sensors, vol. 25, no. 19, 2025.
- [2] V.-K. Wong, S. M. Rabeek, S. C. Lai, M. Philibert, D. B. K. Lim, S. Chen, M. K. Raja, and K. Yao, "Active ultrasonic structural health monitoring enabled by piezoelectric direct-write transducers and edge computing process," Sensors, vol. 22, no. 15, 2022.
- [3] A. Malekloo, E. Ozer, M. AlHamaydeh, and M. Girolami, "Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights," Structural Health Monitoring, vol. 21, no. 4, pp. 1906–1955, 2022.
- [4] D. J. Inman, Damage prognosis for aerospace, civil and mechanical systems. Wiley, 2005.
- [5] D. Sharma, S. Verma, and K. Sharma, "Network topologies in wireless sensor networks: A review," International Journal of Electronics & Communication Technology, vol. 4, no. 3, pp. 93–97, 2013.
- [6] M. Y. Khan, A. Qayoom, M. Nizami, M. S. Siddiqui, S. Wasi, and K.-U.-R. R. Syed, "Automated prediction of good dictionary examples (gdex): A comprehensive experiment with distant supervision, machine learning, and word embedding-based deep learning techniques," Complexity, 09 2021.
- [7] A. Işbitirici, L. Giarre, W. Xu, and P. Falcone, "Lstm-based virtual load sensor for heavy-duty vehicles," Sensors, vol. 24, no. 1, p. 226, 2023.
- [8] G. C. Uribe Riestra, Structural health monitoring of multiscale hierarchical composites by means of an electrical method aided by artificial intelligence algorithms. Doctoral dissertation, Centro de Investigación Científica de Yucatán, A.C. and Université de Toulouse, Mérida, Yucatán, Mexico, March 2026. Subject areas: Polymeric Materials and Electrical Engineering.
- [9] J. Heredia and G. Uribe, "Comunicación privada," June 2025. Virtual Structural Health Monitoring Laboratory (VSHML).
- [10] Y. Yang, W. Xu, Z. Gao, Z. Yu, and Y. Zhang, "Research progress of SHM system for super high-rise buildings based on wireless sensor network and cloud platform," Remote Sens. (Basel), vol. 15, p. 1473, Mar. 2023.

- [11] G. Arana, M. González-Díaz, A. Castillo-Atoche, and F. Avilés, "Improving adhesion between polyimide surface and carbon nanotube arrays for strain-sensing devices," Materials Today Communications, vol. 34, p. 105008, Mar. 2023.
- [12] A. Balam, Z. Valdez-Nava, V. Bley, P. Ayuso-Faber, H. Carrillo-Escalante, A. Castillo-Atoche, and F. Avilés, "Effect of temperature on the electrical and electromechanical properties of carbon nanotube/polypropylene composites," Smart Materials and Structures, vol. 32, p. 085008, June 2023.
- [13] A. Hernández-Benítez, A. Balam, J. Vázquez-Castillo, J. J. Estrada-López, R. Quijano-Cetina, A. Bassam, F. Aviles, and A. Castillo-Atoche, "An ultra-low-power strain sensing node for long-range wireless networks in carbon nanotube-based materials," IEEE Sensors Journal, vol. 22, no. 10, pp. 9778–9786, 2022.
- [14] R. Atoche-Ensenat, E. Perez, A. Hernandez-Benitez, A. Balam, J. J. Estrada-Lopez, J. Vazquez-Castillo, F. Aviles, and A. Castillo-Atoche, "A smart tactile sensing system based on carbon nanotube/polypropylene composites for wearable applications," IEEE Sensors Journal, vol. 23, p. 2948–2955, Feb. 2023.
- [15] F. C. Gül, M. Moradi, and D. Zarouchas, "An integrated approach for prognosis of remaining useful life for composite structures under in-plane compressive fatigue loading," Composites Part C: Open Access, vol. 15, p. 100531, 2024.
- [16] Rajini and P. Voola, "Developing an IoT and ML-driven platform for fruit ripeness evaluation and spoilage detection: A case study on bananas," e-Prime - Advances in Electrical Engineering, Electronics and Energy, vol. 11, p. 100896, mar 2025.
- [17] P. Huang, J. Dong, X. Han, Y. Qi, Y. Xiao, and H. Leng, "Prediction of mechanical properties of composite materials based on convolutional neural network-long and short-term memory neural network," Metalurgija, vol. 63, no. 3-4, pp. 369–372, 2024.
- [18] F. Cui, L. Liang, and X. Chen, "Meta-learning enhanced 3d cnn-lstm framework for predicting durability of mechanical metal–concrete interfaces in building composite materials with limited historical data," Buildings, vol. 15, no. 21, 2025.
- [19] N. T. C. Nhung, H. N. Bui, and T. Q. Minh, "Enhancing recovery of structural health monitoring data using cnn combined with gru," Infrastructures, vol. 9, no. 11, 2024.
- [20] J. Violos, S. Tsanakas, T. Theodoropoulos, A. Leivadreas, K. Tserpes, and T. Varvarigou, "Hypertuning gru neural networks for edge resource usage prediction," in 2021 IEEE symposium on computers and communications (iscc), pp. 1–8, IEEE, 2021.
- [21] Y. Hao, A. Ojha, and Y. Liu, "Lstm and gru based lightweight temporal models for edge computing on real-time individual abnormal behavior recognition," IEEE Transactions on Consumer Electronics, vol. 68, no. 2, pp. 1–1, 2025.

- [22] K.-C. Jung and S.-H. Chang, "Advanced deep learning model-based impact characterization method for composite laminates," Composites Science and Technology, vol. 207, p. 108713, 2021.
- [23] J. Zhang, Z. Cao, Z. Li, and H. Fu, "Research on structural health monitoring of composite material structure based on machine learning method," in 2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing), pp. 1–7, IEEE, 2021.
- [24] C. R. Farrar and N. A. Lieven, "Damage prognosis: the future of structural health monitoring," Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, vol. 365, no. 1851, pp. 623–632, 2007.
- [25] C. Boller, F.-K. Chang, and Y. Fujino, Encyclopedia of Structural Health Monitoring. Wiley, 09 2009.
- [26] A. Rytter, Vibrational Based Inspection of Civil Engineering Structures. Ph.d. thesis, Aalborg University, Aalborg, Denmark, 1993.
- [27] Y. Bao and H. Li, "Machine learning paradigm for structural health monitoring," Structural Health Monitoring, vol. 20, no. 4, pp. 1353–1372, 2020.
- [28] P. Seventekidis and D. Giagopoulos, "Model-based damage identification with simulated transmittance deviations and deep learning classification," Structural Health Monitoring, vol. 21, no. 4, pp. 1510–1525, 2021.
- [29] A. Tahat and A. Al-Zaben, "An evaluation of machine learning algorithms in an experimental structural health monitoring system incorporating lora iot connectivity," in Proceedings of the 2022 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), pp. 1–6, IEEE, 2022.
- [30] P. Frankowski, J. Wiśniewska, and S. Matysik, "Artificial intelligence for personalized rankings of articles—novel embedding method supporting decision-making in systematic literature review," in Proceedings of the 28th European Conference on Artificial Intelligence, (Bologna, Italy), 2025.
- [31] J. Hill, R. Szewczyk, A. Woo, S. Hollar, D. Culler, and K. Pister, "System architecture directions for networked sensors," ACM Sigplan notices, vol. 35, no. 11, pp. 93–104, 2000.
- [32] K. Sharifani and M. Amini, "Machine learning and deep learning: A review of methods and applications," World Information Technology and Engineering Journal, vol. 10, no. 07, pp. 3902–3910, 2023.
- [33] S.-C. Zhang, "Machine learning," in Mathematical Introduction to Deep Learning, pp. 1–35, Singapore: Springer, 2020.
- [34] T. M. Mitchell, "Does machine learning really work?," AI magazine, vol. 18, no. 3, pp. 11–11, 1997.

- [35] Chencho, J. Li, and H. Hao, "Structural damage quantification using long short-term memory (Lstm) auto-encoder and impulse response functions," Journal of Infrastructure Intelligence and Resilience, vol. 3, p. 100086, 2024.
- [36] M. Amini, K. Sharifani, and A. Rahmani, "Machine learning model towards evaluating data gathering methods in manufacturing and mechanical engineering," International Journal of Applied Science and Engineering Research, vol. 15, no. 2023, pp. 349–362, 2023.
- [37] Q. Zhou, H. Zhou, and Q. Zhou, "Structure damage detection based on random forest recursive feature elimination," Mechanical Systems and Signal Processing, vol. 46, no. 1, pp. 82–90, 2014.
- [38] S. Dabetwar, S. Ekwaro-Osire, and J. P. Dias, "Fatigue damage diagnostics of composites using data fusion and data augmentation with deep neural networks," Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, vol. 5, no. 2, 2022.
- [39] H. Liu and S. Liu, "Data-driven approaches for characterization of delamination damage in composite materials," IEEE Transactions on Industrial Electronics, vol. 68, no. 3, pp. 2532–2542, 2021.
- [40] V. V. M. Rao, A. Chaparala, P. K. Jain, H. Karamti, and W. Karamti, "Monitor the strength status of buildings using hybrid machine learning technique," IEEE Access, 2023.
- [41] Y. Bao and H. Li, "Machine learning paradigm for structural health monitoring," Structural Health Monitoring, vol. 20, no. 4, pp. 1353–1372, 2021.
- [42] V. Ahmadian, S. B. B. Aval, M. Noori, T. Wang, and W. A. Altabey, "Comparative study of a newly proposed machine learning classification to detect damage occurrence in structures," Engineering Applications of Artificial Intelligence, vol. 127, p. 107226, 2024.
- [43] X. Qing, Y. Liao, Y. Wang, B. Chen, F. Zhang, and Y. Wang, "Machine learning based quantitative damage monitoring of composite structure," International Journal of Smart and Nano Materials, vol. 13, no. 2, pp. 167–202, 2022.
- [44] M. Azimi, A. D. Eslamlou, and G. Pekcan, "Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review," Sensors (Basel), vol. 20, p. 2778, May 2020.
- [45] S. J. Prince, Understanding Deep Learning. The MIT Press, 2023.
- [46] M. Numan, "Advancements in structural health monitoring: A review of machine learning approaches for damage detection and assessment," International Journal for Computational Civil and Structural Engineering, vol. 20, no. 1, pp. 124–142, 2024.

- [47] O. S. Sonbul and M. Rashid, "Algorithms and techniques for the structural health monitoring of bridges: Systematic literature review," Sensors, vol. 23, no. 9, p. 4230, 2023.
- [48] T. Miyamoto and Y. Yamamoto, "Using 3-d convolution and multimodal architecture for earthquake damage detection based on satellite imagery and digital urban data," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 14, pp. 8606–8613, 2021.
- [49] M. H. Le Nguyen, F. Turgis, P.-E. Fayemi, and A. Bifet, "Real-time learning for real-time data: online machine learning for predictive maintenance of railway systems," Transportation Research Procedia, 2022.
- [50] A. Malhi, R. Yan, and R. X. Gao, "Prognosis of defect propagation based on recurrent neural networks," IEEE Transactions on Instrumentation and Measurement, vol. 60, no. 3, pp. 703–711, 2011.
- [51] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," IEEE transactions on neural networks, vol. 5, no. 2, pp. 157–166, 1994.
- [52] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735–1780, 1997.
- [53] C. Olah, "Understanding lstm networks," Colah's Blog, 2015.
- [54] X. Zhang, Y. Wang, Z. Liu, and M. Chang, "Efectividad de las redes neuronales recurrentes (rnn) y lstm en el modelado de dependencias temporales y la predicción de la vida útil remanente (rul) basándose en señales de ondas guiadas," Revista Iberoamericana de Automática e Informática Industrial, vol. 21, no. 2, pp. 142–154, 2024.
- [55] K. Cho, B. Van Merriënboer, Ç. Gulçehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using rnn encoder–decoder for statistical machine translation," in Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), pp. 1724–1734, Association for Computational Linguistics, 2014.
- [56] A. Califano, N. Chandarana, L. Grassia, A. D'Amore, and C. Soutis, "Damage detection in composites by artificial neural networks trained by using in situ distributed strains," Applied Composite Materials, vol. 27, pp. 657–671, 2020.
- [57] S. Hassani, M. Mousavi, and A. H. Gandomi, "Structural health monitoring in composite structures: A comprehensive review," Sensors (Basel), vol. 22, p. 153, dec 2021.
- [58] K. Zhou, H. Sun, R. Enos, D. Zhang, and J. Tang, "Harnessing deep learning for physics-informed prediction of composite strength with microstructural uncertainties," Computational Materials Science, vol. 197, p. 110663, 2021.

- [59] S. Dabetwar, S. Ekwaro-Osire, and J. P. Dias, "Fatigue damage diagnostics of composites using data fusion and data augmentation with deep neural networks," Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, vol. 5, no. 2, p. 021004, 2022.
- [60] S. Iijima, "Helical microtubules of graphitic carbon," Nature, vol. 354, no. 6348, pp. 56–58, 1991.
- [61] W. Krätschmer, L. D. Lamb, K. Fostiropoulos, and D. R. Huffman, "Solid c60: a new form of carbon," Nature, vol. 347, no. 6291, pp. 354–358, 1990.
- [62] S. Iijima and T. Ichihashi, "Single-shell carbon nanotubes of 1-nm diameter," Nature, vol. 363, no. 6430, pp. 603–605, 1993.
- [63] P. Cassese, C. Rainieri, and A. Occhiuzzi, "Applications of cement-based smart composites to civil structural health monitoring: a review," Applied Sciences, vol. 11, no. 18, p. 8530, 2021.
- [64] C. Rainieri, G. Fabbrocino, Y. Song, V. Shanov, et al., "Cnt composites for shm: a literature review," in Proceedings of the 3rd International Workshop: Smart Materials, Structures & NDT in Aerospace, (Montreal, Canada), pp. 2–4, 2011.