


ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA



Proyecto Fin de Máster

**MACHINE LEARNING APLICADO A LA
PREDICCIÓN DEL DAÑO EN PUENTES: UN
CASO PARTICULAR**

(Machine Learning applied to the prediction
of damage in bridges: particular case)

Para acceder al Título de

**MÁSTER UNIVERSITARIO EN
INGENIERIA INDUSTRIAL**

Autor: Francisco José Iglesias Ruiz

Septiembre – 2020

RESUMEN

En los últimos años, los Sistemas de Monitorización Estructural (*SHM*) han ido ganando importancia en el sector industrial y civil. Uno de los objetivos es dar soporte a los ingenieros para analizar el comportamiento de las estructuras en fase de operación y mantenimiento bajo las condiciones de servicio reales, de forma cuantitativa, para optimizar su gestión y actuar de forma preventiva ante fallos estructurales graves (tanto de seguridad como económicos).

En este trabajo se propone un modelo predictivo basado en técnicas de Machine Learning para controlar la influencia del impacto dinámico de las circulaciones de vehículos reales al pasar sobre un aparato de dilatación de vía localizado sobre la traza de un puente real. Este trabajo parte de los datos de aceleraciones tomadas en distintos puntos de la estructura mediante monitorización real. Finalmente, una vez diseñado el modelo, se formula su integración en el Sistema de SHM con el objetivo de valorar la evolución del comportamiento de la estructura en tiempo real al reactivarse el Sistema de monitorización.

Este TFM se ha desarrollado bajo la colaboración de la Universidad de Cantabria y TECNALIA.

Palabras clave: SHM (Structural Health Monitoring), Machine Learning, Gradient-Boosting, Correlation, Multi-sensor, Montecarlo Analysis.

ABSTRACT

Nowadays, Structural Monitoring Systems (SHM) have been increasing their importance in the industrial and civil fields. One of the objectives is to support engineers to analyze the behavior of structures in the operation and maintenance stage under real service conditions, quantitatively, to optimize their management and act preventively against serious structural failures (economic and security ones).

This project proposes a predictive model based on machine learning techniques to control the influence of the Dynamic impact of real vehicle traffic when passing on a track dilatation apparatus. This work is part of the acceleration data at the different points of the structure through real monitoring. Finally, once the model was designed, it was integrated into the SHM system with the objective of assessing the evolution of the structure's behavior in real time by reactivating the monitoring system.

This TFM has been developed under the collaboration of the University of Cantabria and TECNALIA.

AGRADECIMIENTOS

Agradecer a Daniel Alvear Portilla, en calidad de codirector de proyecto, por su apoyo y disponibilidad siempre que ha sido necesario.

A David García Sánchez, por sus consejos, su manera de transmitir y su ayuda; por sus enormes dosis de paciencia, pilar maestro sin el cual, este trabajo no habría sido posible.

A Ana Fdez-Navamuel, por toda la ayuda y tiempo invertido cuando no era su responsabilidad, lo que da aún más valor a su trabajo.

Para Javier Torres Ruiz, solo palabras de agradecimiento por su guía y su continuo interés a lo largo del camino recorrido en este trabajo. Sin duda una persona ejemplar en su profesión.

ÍNDICE

RESUMEN.....	3
ABSTRACT	4
ÍNDICE.....	6
1. INTRODUCCIÓN	9
1.1. CONTEXTUALIZACIÓN	12
1.2. OBJETIVOS.....	13
2. ESTADO DEL ARTE.....	15
2.1. INTRODUCCIÓN	15
2.2. DEFINICION DE DAÑO	17
2.3. MANTENIMIENTO ESTRUCTURAL	18
2.3.1. MANTENIMIENTO CORRECTIVO.....	18
2.3.2. MANTENIMIENTO PROACTIVO	19
2.3.3. VENTAJAS DEL SHM	20
2.4. SHM	22
2.4.1. Axiomas de los SHM	24
2.4.2. Tipos de sensores	26
2.5. ANÁLISIS MODAL OPERACIONAL Y EXPERIMENTAL	29
2.5.1. Análisis Modal Operacional (AMO).....	29
2.5.2. Análisis Modal Experimental (AME).....	29
2.5.3. ¿AMO o AME?	29
2.6. MACHINE LEARNING AND DATA ANALYTICS	32
2.6.1. Aprendizaje supervisado.....	32
2.6.2. Aprendizaje no supervisado.....	33
2.6.3. Aprendizaje por refuerzo	33
3. METODOLOGÍA.....	34
3.1. INTRODUCCIÓN	34
3.2. SISTEMA DE SHM	34
3.2.1. Sensores	34
3.2.2. Tratamiento de los datos	35

3.2.3.	Extracción de parámetros característicos.....	36
3.3.	EXTRACCIÓN DE SERIES PARA EL DESARROLLO DE POST-PROCESADO DE DATOS ..	37
3.4.	POST-PROCESADO DE DATOS	38
3.4.1.	Machine Learning	38
3.4.2.	Comparación de Modelos de Regresión de ML	40
3.4.3.	Gradient Boosting	41
3.5.	VALIDACIÓN DE HERRAMIENTA.....	42
4.	CASO DE ESTUDIO.....	44
4.1.	INTRODUCCIÓN	44
4.2.	DESCRIPCIÓN DE LA ESTRUCTURA	45
4.3.	OBJETIVO.....	46
4.4.	SISTEMA DE MONITORIZACIÓN	47
4.5.	PREPROCESO	48
4.5.1.	Selección de muestra y periodos temporales	50
4.5.2.	Dominio de la frecuencia: Análisis de Fourier	51
4.5.3.	Resultados	52
4.6.	ESTUDIO ESTADISTICO	53
4.6.1.	Introducción	53
4.6.2.	Objetivo	53
4.6.3.	Análisis de correlación lineal.....	53
4.7.	MODELO PREDICTIVO	57
4.7.1.	Introducción	57
4.7.2.	Selección de acelerómetros: Grado de correlación	57
4.7.3.	Generación de datos adicionales sintéticos mediante Montecarlo (benchmarking sintético)	60
4.7.4.	Regresión Multiple (Multioutput Regressor): Gradient Boosting	60
4.7.5.	Fase 1: Entrenamiento	60
4.7.6.	Fase 2: Validación	62
4.7.7.	Comparación de resultados	63
4.8.	GENERACIÓN DE ESTADOS DE ALARMA	66

4.8.1. Resultados	67
5. CONCLUSIONES	71
5.1. Conclusiones sobre la instrumentación.....	71
5.2. Conclusiones sobre las metodologías basadas en datos.....	72
5.3. Conclusiones sobre Machine Learning y su aplicación en el mantenimiento predictivo	72
5.4. Conclusiones sobre la herramienta de detección de daños	72
ANEXO I: SCRIPTS UTILIZADOS	73
I. PREPROCESO DE DATOS Y CÁLCULO DE FRECUENCIAS	73
II. DISPERSIÓN DE RESULTADOS	80
III. CÁLCULO DE CORRELACIONES	81
IV. MODELO ESTADISTICO	86
ANEXO II: DISEMINACIÓN E IMPACTO CIENTÍFICO.....	90
ANEXO III: BIBLIOGRAFÍA.....	99
INDICE DE FIGURAS	101
INDICE DE TABLAS	101

1 INTRODUCCIÓN

1.1 CONTEXTUALIZACIÓN

A lo largo de la historia, la ingeniería civil ha jugado un rol fundamental en la sociedad y, hoy en día, es prácticamente imposible imaginar un mundo sin puentes, túneles, carreteras, plantas de generación eléctrica, infraestructuras de transporte y energía, en definitiva. Sin embargo, con el paso del tiempo, todas ellas sufren inevitablemente un proceso de deterioro y envejecimiento que puede derivar en una pérdida de las propiedades de los materiales que las constituyen o en alteraciones de las características geométricas, pudiendo comprometer la capacidad de servicio original de la estructura o incluso provocar un fallo inesperado en la misma. También los cambios de uso pueden afectar dicha capacidad, así como los eventos extremos debido al cambio climático.

Además, los avances experimentados en el ámbito de la construcción y la ingeniería han hecho posible diseñar estructuras cada vez más complejas, empleando nuevas técnicas y materiales.

Como consecuencia, con el paso del tiempo se ha desencadenado una necesidad creciente de evolucionar desde las técnicas tradicionales de inspección (visual) hacia metodologías de control autónomas (digital) que proporcionen una visión cuantitativa y precisa sobre la condición real de las estructuras. Esto se consigue mediante un proceso de medición, seguimiento y análisis del nivel de servicio de las estructuras conocido como Monitorización de la integridad Estructural (*SHM*).

Los avances tecnológicos experimentados en las últimas décadas en los ámbitos de la instrumentación y de las Tecnologías de la Información (TICS) han hecho que la *SHM* se convierta en una herramienta accesible a nivel tecnológico, trasladando el reto fundamental hacia la capacidad de estos sistemas de gestionar la gran cantidad de datos disponibles (estructurados o no) para convertirlos en fuentes de información actualizada sobre el estado estructural.

El resultado final es el desarrollo de un modelo de comportamiento de la estructura que permita detectar su estado actual y predecir su estado futuro. En definitiva: la condición operativa actual de la estructura (diagnóstico) y la predicción de la condición futura (pronóstico).

Hoy en día, una de las técnicas empleadas para la definición de esos modelos de evaluación se basa en la modelización inversa, que consiste en identificar aquellos modelos físicos paramétricos (MEF^{*1}) que mejor se ajusten a las respuestas estructurales registradas por los sensores. Este tipo de enfoque requiere un avanzado conocimiento ingenieril sobre el comportamiento físico real de la estructura y los parámetros que deben ser analizados.

Además, en muchos casos, la actualización del modelo con los datos de la instrumentación puede llevar a resultados matemáticamente correctos que sean físicamente imposibles, dando lugar a incongruencias. Esta técnica requiere muchos recursos computacionales a nivel tanto de hardware como de software por lo que hoy día en fase de desarrollo (TRL*² bajo).

De forma alternativa y complementaria, en los últimos años se han desarrollado fuertemente las metodologías basadas en datos, impulsadas por el novedoso concepto de “Big Data”, que trabajan exclusivamente modelos estadísticos. En el ámbito de la *SHM*, estas metodologías aportan un enfoque más flexible y económico, ya que no necesitan desarrollar modelos específicos para cada sistema particular, sino que el mismo procedimiento se ajusta a los datos para proporcionar la solución adecuada.

Por este motivo, y dada la tendencia creciente a disponer de grandes conjuntos de datos que permitan fundamentar de manera segura las modelizaciones estadísticas, en este proyecto se plantea un enfoque basado en datos para la definición de un sistema de *SHM* que disponga de una herramienta capaz de detectar anomalías en el comportamiento estructural de un viaducto ante la existencia de un elemento de discontinuidad en la vía sobre su traza. Mediante la información procedente de la instrumentación de un viaducto real durante un periodo de funcionamiento normal en fase de servicio, se emplearán las técnicas del reconocimiento de patrones estadísticos para resolver un problema de clasificación entre dos posibles estados de la estructura: dañado y no dañado, que permita a la herramienta detectar posibles anomalías en su comportamiento asociadas a esa discontinuidad de vía (bretelle).

1.2 OBJETIVOS

En este proyecto se pretende hacer visible la utilidad de los datos de instrumentación como potencial fuente de información en la creación de herramientas desarrolladas para detectar anomalías en el comportamiento estructural, y que sean capaces de realizar un aprendizaje automático, proporcionando así un soporte cuantitativo y preciso para la toma de decisiones de gestión.

El principal objetivo es aportar una mejora en los métodos de evaluación del estado estructural de los puntos críticos de puentes, mediante las técnicas de *SHM* y siguiendo la línea marcada por David García Sánchez [1] en su Tesis y Ana Fdez-Navamuel del Olmo [2] en su Trabajo Fin de Máster, que supuso un avance en el aprovechamiento de los sistemas de instrumentación existentes.

Se analizará el potencial de los métodos de detección de anomalías basados en datos, proponiendo un nuevo planteamiento que incorpore las técnicas de aprendizaje automático

mediante el reconocimiento de patrones estadísticos para evolucionar de un sistema de monitorización completo (hard-sensing) a uno focalizado y especializado en los puntos críticos de la estructura y que, a su vez nos permita conocer el estado de toda la estructura (soft-sensing). Para ello, se aplicarán estas técnicas a un caso práctico real a partir de los datos de instrumentación de un puente.

Los principales objetivos del proyecto son:

- Demostrar la importancia, cada vez mayor, de la gestión inteligente y correcto tratamiento de las grandes cantidades de datos proporcionados por la instrumentación en el ámbito de la Monitorización Estructural (SHM) y su importancia en la gestión de activos.
- Evolucionar y simplificar los sistemas de monitorización complejos (hard-sensing) mediante un estudio estadístico hacia sistemas sencillos (soft-sensing) justificados matemática y estructuralmente.
- Implementación eficiente de los sistemas SHM y detección de daños aplicando técnicas de Machine Learning a datos de comportamiento dinámico de la estructura.
- Diseño de una herramienta de detección de anomalías “ad-hoc” a un problema estructural real basadas en mejora continua y técnicas de Machine Learning de reconocimiento de patrones a partir de los datos procedentes de la instrumentación de un puente.

2 CONTEXTUALIZACIÓN

A lo largo de la historia, la ingeniería civil ha jugado un rol fundamental en la sociedad y, hoy en día, es prácticamente imposible imaginar un mundo sin puentes, túneles, carreteras, plantas de generación eléctrica, infraestructuras de transporte y energía, en definitiva. Sin embargo, con el paso del tiempo, todas ellas sufren inevitablemente un proceso de deterioro y envejecimiento que puede derivar en una pérdida de las capacidades resistentes de los materiales que las constituyen o en alteraciones de las características geométricas, pudiendo comprometer las condiciones de uso y confort de la estructura o incluso provocar un fallo estructural grave e inesperado en la misma. También los cambios de uso pueden afectar dicha capacidad, así como los eventos extremos debido al cambio climático.

Además, los avances experimentados en el ámbito de la construcción y la ingeniería han hecho posible diseñar estructuras cada vez más complejas, empleando nuevas técnicas y materiales.

Como consecuencia, con el paso del tiempo se ha desencadenado una necesidad creciente de evolucionar desde las técnicas tradicionales de inspección (visual) hacia metodologías de control autónomas (digital) que proporcionen una visión cuantitativa y precisa sobre la condición real de las estructuras. Esto se consigue mediante un proceso de medición, seguimiento y análisis del nivel de servicio de las estructuras conocido como Monitorización de la integridad Estructural (*SHM*).

Los avances tecnológicos experimentados en las últimas décadas en los ámbitos de la instrumentación y de las Tecnologías de la Información (*TICS*) han hecho que la *SHM* se convierta en una “herramienta” accesible a nivel tecnológico, trasladando el reto fundamental hacia la capacidad de estos sistemas de gestionar la gran cantidad de datos disponibles (estructurados o no) para convertirlos en fuentes de información actualizada sobre el estado estructural.

El resultado final es el desarrollo de un modelo de comportamiento de la estructura que permita detectar su estado actual y predecir su estado futuro. En definitiva: la condición operativa en el presente de la estructura (diagnóstico) y la predicción de la condición futura (pronóstico).

Hoy en día, una de las técnicas empleadas para la definición de esos modelos de evaluación se basa en la modelización inversa, que consiste en identificar aquellos modelos físicos

paramétricos (*MEF*¹) que mejor se ajusten a las respuestas estructurales registradas por los sensores. Este tipo de enfoque requiere un avanzado conocimiento ingenieril sobre el comportamiento físico real de la estructura y los parámetros que deben ser analizados.

Además, en muchos casos, la actualización del modelo con los datos de la instrumentación puede llevar a resultados matemáticamente correctos que sean físicamente imposibles, dando lugar a incongruencias. Esta técnica requiere muchos recursos computacionales a nivel tanto de hardware como de software por lo que hoy día en fase de desarrollo (*TRL*² bajo).

De forma alternativa y complementaria, en los últimos años se han desarrollado fuertemente las metodologías “output-only” basadas en datos, impulsadas por el concepto de “Big Data”, que trabajan exclusivamente con modelos estadísticos. En el ámbito de la *SHM*, estas metodologías aportan un enfoque más flexible y económico, ya que no necesitan desarrollar modelos específicos para cada sistema particular, sino que el mismo procedimiento se ajusta a los datos para proporcionar la solución adecuada.

Por este motivo, y dada la tendencia creciente a disponer de grandes conjuntos de datos que permitan fundamentar de manera segura las modelizaciones estadísticas, en este proyecto se plantea un enfoque basado en datos para la definición de un sistema de *SHM* que disponga de una herramienta capaz de detectar anomalías en el comportamiento estructural de un viaducto derivado del tráfico sobre un elemento de discontinuidad en la vía sobre la traza del puente. Esta herramienta se basa en técnicas del reconocimiento de patrones estadísticos identificando dos posibles estados de la estructura: dañado y no dañado. De este modo la herramienta podrá detectar posibles anomalías en estructurales asociadas a esa discontinuidad de vía (*bretelle*).

2.1 OBJETIVOS

En este proyecto se pretende hacer visible la utilidad de los datos de instrumentación como potencial fuente de información en la creación de herramientas desarrolladas para detectar anomalías en el comportamiento estructural, y que sean capaces de realizar un aprendizaje

¹ *MEF*: Método de Elementos Finitos (*MEF* en castellano o *FEM* en inglés) es un método numérico general para la aproximación de soluciones de ecuaciones diferenciales parciales muy complejas utilizado en diversos problemas de ingeniería y física.

² *TRL*: Nivel de madurez tecnológica (Technological Readiness Level). Bloques constitutivos de un método para estimar la madurez de las tecnologías durante la fase de adquisición de un programa. El uso de *TRLs* permite discusiones consistentes y uniformes sobre la madurez técnica en diferentes tipos de tecnología. El *TRL* de una tecnología se determina mediante una Evaluación de Madurez Tecnológica (*TRA*) donde se examinan los conceptos del programa, los requisitos y las capacidades tecnológicas demostradas. Los *TRLs* se determinan utilizando una escala del 1 al 9, siendo 9 la tecnología más madura.

automático, proporcionando así un soporte cuantitativo y preciso para la toma de decisiones de gestión.

El principal objetivo es aportar una mejora en los métodos de evaluación del estado estructural de los puntos críticos de puentes, mediante las técnicas de *SHM* y siguiendo la línea marcada por David García Sánchez ³[1] en su Tesis y Ana Fdez-Navamuel del Olmo⁴ [2] en su Trabajo Fin de Máster, que supuso un avance en el aprovechamiento de los sistemas de instrumentación existentes.

Se analizará el potencial de los métodos de detección de anomalías basados en datos, proponiendo un nuevo planteamiento que incorpore las técnicas de aprendizaje automático mediante el reconocimiento de patrones estadísticos para evolucionar de un sistema de monitorización completo (*hard-sensing*) a uno focalizado y especializado en los puntos críticos de la estructura y que, a su vez nos permita conocer el estado de toda la estructura mediante un esquema de monitorización más reducido (*soft-sensing*). Para ello, se aplicarán estas técnicas a un caso práctico real a partir de los datos de instrumentación de un puente.

Los principales objetivos del proyecto son:

- Demostrar la importancia, cada vez mayor, de la gestión inteligente y correcto tratamiento de las grandes cantidades de datos proporcionados por la instrumentación en el ámbito de la Monitorización Estructural (*SHM*) y su importancia en la gestión de activos.
- Evolucionar y simplificar los sistemas de monitorización complejos (*hard-sensing*) mediante un estudio estadístico hacia sistemas sencillos (hacia el *soft-sensing*) justificados matemática y estructuralmente.
- Implementación eficiente de los sistemas *SHM* y detección de daños aplicando técnicas de Machine Learning a datos de comportamiento dinámico de la estructura.
- Diseño de una herramienta de detección de anomalías “*ad-hoc*” a un problema estructural real basadas en mejora continua y técnicas de Machine Learning de reconocimiento de patrones a partir de los datos procedentes de la instrumentación de un puente.

³ David García Sánchez. Control Estadístico y modelos de Regresión lineal. Una forma práctica de control de puentes. Universidad de Cantabria. (2016)

⁴ Ana Fdez-Navamuel del Olmo. Desarrollo de una herramienta de detección de daños para la toma de decisión en gestión de puentes. Universidad de Cantabria. (2018)

3 ESTADO DEL ARTE

3.1 INTRODUCCIÓN

La Monitorización de la salud Estructural o Structural Health Monitoring (*SHM*), es una tecnología de gran importancia en muchas áreas de investigación, como las ingenierías aeroespacial, civil, mecánica, sanitaria y biomédica ya que constituye una herramienta muy potente para asegurar la integridad y la seguridad de los sistemas estructurales tanto en fase de construcción como de operación y mantenimiento.

La *SHM* consiste en la implementación de una estrategia de detección de daños en estructuras, combinando una serie de sensores incorporados a sistemas hardware y software encargados de capturar, transmitir, almacenar y analizar los datos en tiempo real. La capacidad de monitorizar una estructura y detectar posibles daños en sus etapas más tempranas de desarrollo proporciona información muy valiosa para la gestión de las estrategias de mantenimiento y permite realizar predicciones muy precisas de la vida remanente de una estructura. Pasando de estrategias de mantenimiento correctivo a proactivo (preventivo y predictivo).

El diagnóstico de daños en los sistemas estructurales implica principalmente la identificación del daño, junto con una posterior caracterización de su detección, extensión y evidencia. Un sistema robusto de *SHM* estará compuesto de las etapas mostradas en la *Figura 3.1*. Etapas de un SHM.:



Figura 3.1. Etapas de un SHM.

La idea que reside detrás de este flujo operacional consiste en que cuanto mayor sea el nivel de valoración de daños que aporte el sistema de *SHM*, más información se tendrá acerca del daño

presente en la estructura, teniendo en cuenta que esto implica un aumento directo de la dificultad para adquirir la información útil. Por tanto, cada uno de los niveles demandará unos requisitos más exigentes en cuanto al tipo y número de sensores necesarios, así como una complejidad adicional en los algoritmos empleados para la evaluación del daño y en el número de parámetros necesarios. La dificultad reside en desarrollar sistemas de *SHM* que puedan responder de forma óptima a más de una etapa de identificación del daño, tanto en condiciones operativas normales como después de eventos catastróficos como terremotos.

- El nivel 1 únicamente proporcionará información relativa a la posible existencia de un daño en la estructura. En este punto de conocimiento, la realización de unas pocas mediciones de vibración podría ser suficiente para determinar la presencia de algún daño.
- El nivel 2 enriquece el conocimiento sobre el daño detectado, identificando su ubicación (una o varias), para lo que normalmente se emplea un modelo estructural.
- El nivel 3 se encarga de caracterizar el tipo de daño presente en la estructura, considerando daño como “algún cambio introducido en el sistema”, que puede ser algún tipo de grieta, una alteración de las condiciones de contorno o una modificación en las conexiones de los miembros estructurales.
- El nivel 4 permite estimar el tamaño o la extensión del daño, y para ello es necesario que el modelo represente adecuadamente el efecto del daño sobre la estructura, por ejemplo, modificando la longitud de grieta o la reducción de la rigidez estructural. Si no es posible lograr este modelo, se tendría que realizar experimentos de calibración.
- El nivel 5 se encarga de predecir la vida útil remanente de la estructura en base al conocimiento adquirido sobre el daño. Esto es lo que se conoce como nivel de pronóstico y resulta del desarrollo y maduración de las tecnologías de *SHM*, ya que permite una mejor comprensión de la progresión del daño. Este nivel requiere la combinación de un modelo estructural global junto con modelos locales de continua evolución del deterioro.

En resumen, la *SHM* constituye una fuente de información constante sobre la condición actual de un sistema o estructura, con la intención no solo de conocer si ha sufrido algún deterioro, sino de ser capaces de evaluar los niveles de servicio a futuro e incluso la vida útil remanente derivada de la presencia de los deterioros.

3.2 DEFINICION DE DAÑO

De forma genérica, el daño puede definirse como aquellos cambios introducidos en un sistema, tanto intencionada como inintencionadamente, que afectan de forma negativa a su comportamiento normal. Este proyecto se centra en la fase de detección de daños en sistemas estructurales y mecánicos, como los puentes, por lo que la definición de daño puede expresarse como *“aquellos cambios inducidos en los materiales o las propiedades geométricas de estos sistemas que afectan adversamente a su funcionamiento normal en fase de servicio u operación”*.

Considerando el concepto a gran escala, el daño siempre comienza a nivel de material, y ese daño a nivel de material está presente de alguna manera en todos los sistemas estructurales. Los científicos de materiales y los físicos suelen hacer referencia a este tipo de daños como “defectos”, ya que son inherentes al proceso de construcción y, por tanto, inevitables.

Sin embargo, bajo determinados escenarios de carga, este daño a nivel de material puede progresar hasta alcanzar el nivel de componente o incluso el nivel de sistema. De este modo, se considera que el fallo estructural total ocurre cuando el daño progresa hasta un punto en que el sistema ya no es capaz de realizar su función o servicio. Típicamente, esta condición de fallo se caracteriza mediante algún valor cuantitativo de esfuerzo, deformación, u otro criterio de funcionamiento.

Es evidente que, a pesar de que el daño está presente en cierta medida en todos los sistemas ingenieriles, las prácticas de diseño modernas permiten controlar esos defectos para que los sistemas funcionen adecuadamente en su presencia. Además, el daño puede ir acumulándose de forma progresiva durante los largos períodos de servicio de las estructuras, originando los fenómenos de fatiga y corrosión.

A continuación, se describen algunos ejemplos de daño que ocurren frecuentemente en los sistemas estructurales.

- Grietas que aparecen en un componente mecánico producen un cambio en la geometría que altera las características de rigidez de dicho componente, mientras que a penas afecta al material o a las condiciones de contorno de la estructura.
- Socavaciones en las pilas de los puentes (corrimiento): es un proceso que tiene lugar cuando un aumento de las corrientes que fluyen alrededor de la pila hace erosionar el suelo o tierra que rodea y retiene a la pila, haciendo que pierda su asentamiento. Se puede ver como un cambio

en las condiciones de contorno del puente, que puede comprometer la integridad estructural sin que haya alteración en las propiedades de masa y rigidez.

- La pérdida de una conexión atornillada en una estructura es un daño que afecta a la conectividad entre elementos, permaneciendo en este caso también invariables la rigidez y la masa de la estructura. Este tipo de daño puede deberse a problemas de corrosión.
- La fatiga aparece como resultado de las cargas cíclicas a las que se ven sometidas las estructuras durante su vida útil, que pueden ser derivadas de agentes atmosféricos (temperatura, vientos) u operacionales (derivados de la carga a soportar como el tráfico).

Este daño siempre debe llevar asociado un indicador de daño (*Damage Index*) para el control de su evolución y activación de alarmas.

3.3 MANTENIMIENTO ESTRUCTURAL

Realizar un correcto mantenimiento de las estructuras es fundamental para que funcionen correctamente y evitar así averías y accidentes inesperados, con los correspondientes daños humanos y económicos.

Para controlar el estado de salud de dicha estructura se pueden llevar a cabo diferentes tipos de mantenimiento. Cuando hablamos de tipos de mantenimiento en realidad nos estamos refiriendo a la estrategia que se toma con relación a sus tareas de mantenimiento.

El mantenimiento se puede clasificar siguiendo diferentes criterios, como por ejemplo la especialidad de la tarea (mantenimiento eléctrico, de instrumentación, mecánico) o de acuerdo con su peligrosidad (mantenimientos que requieren permisos especiales).

No obstante, a continuación, veremos los tipos de mantenimiento en función a la naturaleza de sus tareas que son: el mantenimiento correctivo y el mantenimiento proactivo.

3.3.1 MANTENIMIENTO CORRECTIVO

El mantenimiento correctivo es también conocido como reactivo. Es el método más tradicional y con uso más extendido. Es un tipo de mantenimiento que se basa en arreglar las averías conforme van surgiendo.

No requiere ninguna planificación sólo requiere ir atendiendo día a día las averías que necesitan ser reparadas en la estructura. Para realizarlo puede llegar a ser necesario detener el uso de la estructura parcial o totalmente, con lo que eso conlleve.

Para minimizar su impacto durante el proceso de reparación, se necesita que el departamento de mantenimiento esté bien dimensionado contando con los operarios de mantenimiento necesarios para reparar las averías en el mínimo tiempo posible.

3.3.2 MANTENIMIENTO PROACTIVO

Se divide a su vez dos tipos de mantenimiento, mantenimiento preventivo y predictivo.

Al mantenimiento preventivo, también se le llama mantenimiento planificado. El mantenimiento preventivo trata de un conjunto de tareas de mantenimiento que tienen como objetivo mantener las instalaciones anticipándose a las averías.

Su objetivo es seguir consiguiendo las mismas prestaciones de la estructura y sus equipos y compensar el desgaste que van sufriendo con el paso del tiempo, pero siempre antes de que surja una avería y de manera preventiva para evitarlos en el futuro.

Tienen un carácter sistemático, es decir que se realizan o bien por horas de funcionamiento o por periodos de tiempos. Se tiene un registro del tiempo que tardan los componentes más importantes (críticos) en averiarse.

Una ventaja con respecto al mantenimiento correctivo es el aprovechamiento de tiempos con menor carga de trabajo para llevarlo a cabo las reparaciones.

El mantenimiento predictivo es el más tecnológico de los tres tipos de mantenimiento. Se trata de un conjunto de tareas de mantenimiento que relacionan una variable física o química con el estado en que se encuentra la máquina, con el fin de predecir cuándo empieza a fallar un determinado componente de la estructura. Requiere un conocimiento amplio sobre la estructura que se quiere controlar.

Hay diferentes tipos de mantenimientos predictivos, diferentes técnicas para desarrollarlo como por termografías, ultrasonidos, análisis de vibraciones, análisis de aceites, humos combustión, etc.

Algunos ejemplos de los parámetros que utiliza el mantenimiento predictivo pueden ser: vibración de la estructura, temperatura de las conexiones, tensiones soportadas en una determinada zona etc.

Este tipo de programas de mantenimiento reporta un gran ahorro de costes ya que además de detectar los fallos de manera precoz permite programar con suficiente antelación el tiempo de reparación, los suministros y mano de obra que requerirá la tarea.

Su principal inconveniente es la dificultad que conlleva obtener una respuesta clara y segura ya que no existe ningún parámetro ni conjunto de parámetros que revele a la perfección el estado de la estructura. Es necesario un análisis completo previo.

3.3.3 VENTAJAS DEL SHM

Los beneficios de disponer de un sistema de seguimiento del comportamiento estructural en un puente o en cualquier otra estructura significativa son muchos y dependen de la aplicación específica en la que se implemente el sistema. Algunos de los más comunes se presentan a continuación:

Reduce la incertidumbre

Los propietarios de puentes están constantemente enfrentándose a grandes incógnitas e incertidumbres: el estado real de los materiales, las cargas reales que actúan sobre la estructura, o el nivel de envejecimiento.

A la hora de tomar una decisión, se deben tener en cuenta todas estas incertidumbres y mantener la estructura siempre del lado de la seguridad, asumiendo para ello el peor de los casos posibles. La monitorización supone una clara reducción de esta incertidumbre, y por tanto permite al propietario tomar decisiones objetivas y fiables fundamentadas en los datos registrados.

Ayuda a objetivar el índice de daño (*Damage Index*).

Descubre el potencial estructural oculto

A lo largo de su vida útil, muchas estructuras pueden encontrarse en una condición mucho mejores de lo esperado. En estos casos, la monitorización permitiría incrementar los márgenes de seguridad de la estructura sin realizar ninguna intervención.

Aprovechar las mejores propiedades de los materiales, los sobre dimensionamientos y otros efectos, hace posible extender de forma segura la vida útil o la capacidad de soporte de carga de las estructuras, sin necesidad de ningún tipo de intervención o prueba y por lo tanto retrasar las acciones de reparación y reducir los costes de sustitución.

Descubre defectos a tiempo y aumenta la seguridad estructural

Algunas estructuras podrían presentar defectos que no son fácilmente detectables por medio de inspecciones visuales. En estos casos, es crucial llevar a cabo una acción reparadora o preventiva antes de que sea demasiado tarde.

Las tareas de reparación son más baratas y causan menores alteraciones en el uso de la estructura cuando se ejecutan a tiempo. Para ello, nada mejor que disponer de datos fiables constantemente monitoreados sobre la estructura, mejorando la seguridad de esta y la de sus usuarios.

Asegura calidad a largo plazo

Cualquier política de calidad implica unas mediciones y una retroalimentación que asegure que los objetivos perseguidos sean conseguidos y que se lleven a cabo acciones correctivas en caso de desviaciones con respecto al estado de referencia.

Mediante la disposición constante de datos, el sistema de monitorización ayuda en la valoración de la calidad de la estructura durante la construcción, el funcionamiento, el mantenimiento y las reparaciones, eliminando así los costes “ocultos” de la no - calidad. La mayoría de los defectos y daños que sufre una estructura aparecen durante la etapa de construcción. Sin embargo, muchos de ellos se hacen visibles mucho tiempo después, haciendo que los costes de reparación sean más elevados y quedando ya fuera de garantía.

Permite una gestión estructural optimizada

Los datos derivados de la *SHM* pueden emplearse para aplicar un mantenimiento a medida, cuando sea necesario, optimizando el funcionamiento de la estructura, así como las labores de mantenimiento, reparo y sustitución en base a datos fiables y objetivos. Los datos pueden integrarse en los sistemas de gestión, incrementando así la calidad de las decisiones al proporcionar información objetiva y fiable que permita a los propietarios invertir en mantenimiento y reconstrucción cuando sea necesario y no solo cuando los fondos estén disponibles. También pueden combinarse con las técnicas de inspección visual para dar lugar a una gestión óptima de los recursos.

Incrementa el conocimiento

Aprender cómo se comporta una estructura en condiciones reales de funcionamiento ayudará a diseñar mejores estructuras en el futuro, más baratas, seguras y duraderas. Una pequeña inversión adicional en el inicio del proyecto puede originar grandes ahorros a través de la optimización del diseño y de la detección a tiempo de las debilidades.

3.4 SHM

La programación de las tareas de mantenimiento y la priorización de la asignación de recursos a los distintos componentes de una red de infraestructuras es crucial para una gestión eficiente.

Con el desarrollo de las técnicas de *SHM*, las estrategias de mantenimiento también han ido evolucionando para optimizar los sistemas de gestión de puentes en términos económicos y de seguridad. Originalmente, el mantenimiento de estructuras se basaba en una filosofía denominada “*run to failure*” que consiste en dejar que el sistema opere normalmente hasta que algún componente clave falle y por tanto deba ser reemplazado. Con esta metodología no se necesitaba una inversión inicial para la implementación y el empleo de sistemas de instrumentación, pero existía un alto riesgo de que ocurriera un fallo inesperado que la convertía en una técnica potencialmente costosa y arriesgada.

Un enfoque un poco más sofisticado con respecto al anterior es el ampliamente utilizado en la actualidad, que se conoce como “*time-based*” y en el que los componentes críticos son tratados o reemplazados en tiempos programados con antelación, sin atender al estado real del elemento, que puede estar perfectamente cuando se realiza la intervención, implicando un coste innecesario, o bien puede haber fallado antes del tiempo programado de revisión. En muchos casos, este tipo de estrategia se combina con un sistema de monitorización que registre algunos valores y programe las tareas de mantenimiento de forma dinámica, en base a la información adquirida por los sensores; por ejemplo, la inspección se efectúa cuando se repita un cierto número de sobrecargas.

El drástico cambio experimentado en las últimas décadas en la programación de las estrategias de mantenimiento se ha debido fundamentalmente al desarrollo de los sistemas inteligentes de *SHM*, y presenta una gran eficiencia en términos de coste y seguridad.

Los avances tecnológicos en el ámbito de la instrumentación han permitido que las estrategias basadas en tiempos evolucionen hacia las filosofías de mantenimiento basadas en la condición o el estado real de los componentes de la estructura. Este concepto de mantenimiento se basa en el empleo de un sistema de sensores que registren la respuesta del sistema y notifiquen la presencia de daños o anomalías. Esto solo podrá conseguirse si el sistema proporciona la información con antelación suficiente para efectuar las acciones correctivas necesarias antes de que el problema se convierta en crítico. De este modo, se consigue extender el ciclo de mantenimiento y, por lo tanto, mantener el equipamiento operativo durante más tiempo.

Por tanto, la *SHM* está siendo actualmente utilizada para proporcionar información objetiva que ayude en la elaboración de planes estratégicos de mantenimiento con el mínimo impacto

negativo sobre la sociedad en términos de seguridad y accesibilidad, y que además reduzca los costes totales incurridos.

Esta nueva visión de los planes de mantenimiento permite efectuar una mejor gestión de los recursos disponibles por parte de los propietarios de grandes redes de infraestructuras y, por lo tanto, contribuye de forma clara a minimizar los costes globales del ciclo de vida de estas. Este aspecto, conocido como “*Life Cycle Costing*” (*LCC*) es una metodología que trata de evaluar todas las posibles alternativas de gestión de las estructuras, incluyendo las estrategias de mantenimiento, para encontrar aquella que satisfaga los requisitos obligatorios de la forma más económica.

Además, gracias a las nuevas concepciones de los proyectos, donde muchas veces el contratado debe encargarse del diseño, construcción, financiación y mantenimiento, en los últimos años está apareciendo un creciente interés por la integración de cuatro aspectos fundamentales en el ámbito de las infraestructuras, que hasta ahora se consideraban de forma independiente: fiabilidad, disponibilidad, mantenimiento y seguridad.

La técnica de integrar estos cuatro aspectos en un único indicador que proporcione información fiable para la toma de decisiones es lo que se conoce como metodología *RAMS* (*Reliability, Availability, Maintenance and Security*), y forma parte, junto con el *LCC*, de las herramientas necesarias para llevar a cabo una gestión eficiente de las estructuras.

3.4.1 Axiomas de los SHM

El fuerte desarrollo de las tecnologías de *SHM* a lo largo de los últimos 20 años, ha hecho posible definir unos axiomas o generalidades basados en estudios experimentales que los corroboran. Estos principios elementales se presentan a continuación:

- **Axioma I:** Todos los materiales presentan defectos o fallos inherentes. Cualquier material tendrá defectos a nivel microestructural como huecos, inclusiones o impurezas. Con todo, los ingenieros han aprendido a superar y aceptar los fallos de diseño derivados de las imperfecciones inevitables de los materiales.
- **Axioma II:** La valoración del daño requiere una comparación entre dos estados del sistema y por lo tanto cualquier enfoque de *SHM* requiere de un modelo de referencia o base. La composición del conjunto de datos de entrenamiento del algoritmo dependerá de si únicamente se tiene intención de detectar la presencia de daños, o si se busca ir más allá, obteniendo información sobre el tipo, extensión y localización de estos, en cuyo caso el conjunto de datos estaría compuesto por mediciones del estado de referencia y mediciones correspondientes al estado o estados dañados.
- **Axioma III:** Mediante modos de aprendizaje no supervisado es posible detectar la existencia y la localización de un daño, pero su caracterización exhaustiva en cuanto a extensión y tipo generalmente solo puede ser alcanzada por medio de algoritmos de aprendizaje supervisado. En esta técnica, los algoritmos se aplican a datos que solo contienen información sobre el estado de referencia de la estructura, siendo el más empleado el conocido como detección de anomalías. Por otro lado, las técnicas de aprendizaje supervisado se aplican cuando se dispone de datos tanto del estado de referencia como de las condiciones dañadas o de fallo, siendo en este caso los algoritmos más conocidos la clasificación en grupo y el análisis de regresión.
- **Axioma IV-a:** Los sensores no pueden medir daño directamente. La extracción de parámetros característicos mediante el procesamiento de señal y la clasificación estadística es un paso imprescindible para convertir las mediciones en información. El objetivo fundamental de los algoritmos de *SHM* consiste en relacionar un estado dañado "*D*" con alguna cantidad medible *X*, en la forma simplificada de $x = \{f(D)\}$. Esta función $\{f\}$ no es conocida directamente, sino que ha de ser obtenida a partir de la información reunida por los sensores.
- **Axioma IV-b:** Si no se realiza una extracción inteligente de parámetros característicos, cuanto más sensibles sean las mediciones al daño, más sensibles serán también a las variaciones en las condiciones operacionales y ambientales, dificultando su capacidad

de detectar daños. La idea fundamental de este axioma reside en que los parámetros característicos que se extraigan de las mediciones evidentemente dependerán del daño a identificar, pero también estarán afectados por las variaciones ambientales y operacionales. Por lo tanto, se debe encontrar un algoritmo donde la respuesta dependa principalmente del daño y la sensibilidad a otros factores quede controlada.

- **Axioma V:** La duración y las escalas de tiempo asociadas para la iniciación y evolución de los daños definen las propiedades del sistema de sensores de la *SHM*. El daño puede acumularse gradualmente a lo largo del tiempo, pero también puede resultar de un evento discreto repentino. Por este motivo, una cuantificación a priori de estas escalas temporales permitirá al sistema de sensores trabajar de una forma más eficiente, escogiendo los componentes de hardware más apropiados para la situación.
- **Axioma VI:** Existe un cierto conflicto entre la sensibilidad al daño que pueda tener un algoritmo, y su capacidad de rechazar señales de ruido contaminantes. De acuerdo con el axioma IV-b, las mediciones obtenidas por el sistema de sensores incluirán efectos asociados tanto a daños como a ruido derivado de las condiciones de contorno y el reto consiste en separar cada una de las fuentes de influencia sobre la señal.
- **Axioma VII:** La magnitud del daño que puede ser detectado mediante cambios en la dinámica del sistema es inversamente proporcional al rango de la frecuencia de excitación. En el campo de los ensayos no destructivos ultrasónicos, el límite de difracción suele asociarse con el mínimo tamaño de defecto detectable como una función de la longitud de onda ultrasónica. Este límite indicará que cualquier defecto de tamaño comparable a la mitad de la longitud de onda será fácilmente detectable.
- **Axioma VIII:** El daño aumenta la complejidad de una estructura. Esto es fácilmente comprensible si se piensa que el daño inducirá no linealidades en un sistema estructural originalmente asumido como lineal.

3.4.2 Tipos de sensores

En este apartado se explicará brevemente la tipología de los sensores más utilizados tal y como se recoge en la Tesis de David García Sanchez [1] . La *Tabla 3.1*. Tipos de sensores extraída de dicha Tesis recoge un inventario de los principales tipos de sensores indicando su naturaleza y funcionalidad.

Tabla 3.1. Tipos de sensores

Categoría	Tipología	Sensor
Medioambientales	Viento	Anemómetro
		Barómetro
	Temperatura	Termómetro
	Corrosión	Indicador de corrosión
		Higrómetro
Sismo	Acelerómetro	
Acciones de tráfico	Carretera	Peso de vehículos
		Galga dinámica
		Cámara de video
	Ferrocarril	Galga dinámica
		Cámara de video
Características del puente	Estático	Estación total
		GPS
	Dinámico	Acelerómetro
Respuesta Estructural	Fuerza en cable	Acelerómetro
	Geometría	GPS
		Estación total
		Transductor de desplazamiento
		Clinómetro
		Termómetro
		Extensómetro
	Estado tensional	Extensómetro
		Célula de carga
		Galga tenso-magnética
Fatiga	Galga dinámica	

Sensores analíticos

Un sensor puede involucrar diversos principios de operación, por lo cual, es elegido dependiendo de las características y las necesidades del operador. Los más comunes son del tipo capacitivo, electromagnético, inductivo, piezoeléctrico y resistivo. Los principales sensores para medir el comportamiento estructural de un puente se describen a continuación:

- Clinómetros: Miden giros ($mRad$) en direcciones longitudinal y transversal. El clinómetro se convierte en el principal indicador de la respuesta deformacional de la estructura a lo largo del tiempo para fuerzas horizontales. Ante cualquiera de estas acciones horizontales (fuerzas de lazo, fuerza centrífuga, viento transversal y longitudinal, fuerzas

horizontales si son punto fijo, rozamiento inducido a través del aparato de apoyo, etc.). Lógicamente, la conversión de los datos del clinómetro en esfuerzos y flechas obliga a conocer la rigidez real de la estructura (o parte de la estructura) en servicio, por lo que es necesario disponer de un modelo de cálculo de la subestructura que pueda evaluar los fenómenos de no linealidad material y geométrica.

- Sondas de temperatura: Las sondas de temperatura, adheridas a las superficies metálicas o introducidas en los volúmenes de hormigón, miden temperatura ($^{\circ}\text{C}$). En este caso la medida de la temperatura se realiza en diversas secciones de pilas y tablero, de esta forma se puede conocer la variación diaria que experimenta el gradiente de temperatura sobre la pila y sobre el tablero, y correlacionar los resultados obtenidos con el giro real medido por el clinómetro. Es decir, se trata de descontar el efecto que tienen los gradientes térmicos en la deformación de la estructura, para obtener así la parte de giro debida realmente a la carga viva y al viento.
- Anemómetros: Los anemómetros miden la velocidad del viento (m/s) y su dirección. Esta medida permite establecer un registro continuo de la intensidad y dirección de la acción del viento, calibrando especialmente la importancia de las ráfagas. Estos anemómetros miden de forma dinámica y continua extrayendo exclusivamente parámetros estadísticos, pero al paso de circulaciones reales o ante la superación de eventos prefijados ofrecen registros temporales para un posterior análisis. Así pues, por ejemplo, es posible caracterizar la respuesta de la estructura frente a distintas intensidades de la acción del viento en combinación con la sobrecarga
- Acelerómetros: Miden aceleraciones, uni o multiaxiales en los puntos de control (m/s^2). Los acelerómetros verticales instalados en tablero permiten realizar un estudio espectral de la vibración originada por la circulación. Informan acerca de las condiciones de confort ante el paso de los vehículos, de la rigidez y amortiguamiento de la estructura (y su posible variación a lo largo del tiempo). Se colocan en las secciones de centro de luz de los vanos más representativos, y en los vanos más sensibles del tablero (vanos extremos libres). También se pueden instalar acelerómetros longitudinales y transversales en el tablero, para obtener la respuesta de la estructura frente a fuerzas centrífugas y de frenado o viento.
- Transductores de desplazamiento: Miden el desplazamiento relativo entre dos puntos de control (m). El objetivo principal de esta medida es conocer el desplazamiento longitudinal relativo tablero – subestructura en determinadas secciones. Para ello, se

colocaron transductores horizontales longitudinales entre tablero y coronación de pilas, y entre tablero y estribos.

- Bandas extensométricas: Las bandas extensométricas miden microdeformaciones ($\mu\epsilon$). Se colocan adheridos a las chapas metálicas, en caso de que se trate de un puente con tablero metálico. Los extensómetros se sitúan en las esquinas de las losas superior e inferior, por lo general. Las secciones del tablero a instrumentar deben ser las mismas elegidas para la colocación de los acelerómetros verticales, tanto en posición de centro de luz como en pila.
- Condiciones ambientales: Se suele colocar una estación meteorológica en las inmediaciones del puente o incluso sobre un pretil. Básicamente, se trata de una instalación destinada a medir y registrar regularmente diversas variables meteorológicas (lluvia, viento, humedad, presión atmosférica...).

Sensores de fibra óptica

La fibra óptica es un medio de transmisión de redes de datos. Consiste en un hilo muy fino cilíndrico, de vidrio o plástico transparente, a través del cual se envían datos mediante pulsos de luz.

Un sensor de fibra óptica es un dispositivo que utiliza la luz para medir una magnitud física, y la fibra óptica como medio de transmisión desde la fuente hasta el detector. En función de cómo se realice la medición existen dos tipos de sensores:

- Extrínsecos: la fibra óptica se utiliza sólo como medio de transmisión.
- Intrínsecos: la luz permanece en todo momento en el interior de la fibra óptica, y sobre dicha fibra se produce la perturbación.

La fibra de medida está conectada a la estructura en dos puntos y, por tanto, se deforma igual que ésta; sin embargo, esta fibra también se alargará o acortará en función de la temperatura. La segunda fibra -fibra de referencia- sirve para compensar este efecto; esta fibra, aunque también está unida a la estructura en dos puntos, tiene una longitud mayor que la distancia entre los mismos y, por tanto, no está influenciada por las deformaciones de la estructura. De esta forma, ambas fibras se deformarán la misma cantidad ante las variaciones térmicas. El sensor mide la diferencia de alargamiento-acortamiento entre ambas fibras, por lo que la deformación propia debida al efecto térmico desaparece.

Los sensores de fibra óptica más utilizados son los interferómetros y las redes de Bragg.

3.5 ANÁLISIS MODAL OPERACIONAL Y EXPERIMENTAL

3.5.1 Análisis Modal Operacional (AMO)

En el análisis modal tradicional los parámetros modales se obtienen de las funciones de respuesta en frecuencia (*FRFs*), que relacionan la salida (respuesta) con la entrada (excitación). Para este tipo de análisis es necesario conocer la entrada y la salida del sistema.

El análisis modal operacional⁵ [3] se basa en la medida de la respuesta de la estructura usando sólo el ambiente (viento) como fuente excitadora. Se usa para obtener una descripción modal de la estructura bajo condiciones ambientales. En vez de cargar la estructura artificialmente y tratar la excitación ambiental como una fuente de ruido no deseado, la excitación natural se usa como fuente de excitación.

3.5.2 Análisis Modal Experimental (AME)

También es posible determinar las frecuencias naturales y modos de vibración de una estructura mediante ensayos experimentales, pruebas de carga o bajo condiciones de operación. En este caso, el procedimiento se denomina Análisis Modal Experimental⁶ [4]. Los resultados de las pruebas experimentales pueden usarse para calibrar un modelo de elementos finitos para determinar si las hipótesis de carga subyacentes hechas fueron correctas (Por ejemplo, módulo de elasticidad de los materiales, densidades, o incluso condiciones de borde consideradas en el modelo).

3.5.3 ¿AMO o AME?

Es de suma importancia conocer el tipo de ensayo, prueba o el tipo de análisis que se necesita realizar de una estructura. Para ello es necesario conocer el comportamiento de dicha estructura a priori, así como los tipos de cargas a los que está sometida. Las cargas de servicio de la estructura pueden ser de naturaleza diversa y frecuencias de excitación muy diferentes. Esto hace que la forma de llevar a cabo el análisis varíe en gran medida dependiendo de cuánto se parezcan esas frecuencias de excitación de las cargas de servicio a las frecuencias de los efectos ambientales a los que está sometida de la estructura.

Dependiendo de esto, los modos de excitación de la estructura serán diferentes en unos casos u otros.

⁵ Carlo Rainieri, Giovanni Fabbrocino. Operational Modal Analysis of Civil Engineering Structures. (2014)

⁶ Joel P. Conte, Rodrigo Astroza, Gianmario Benzoni, Glauco Feltrin, Kenneth J. Loh. Experimental Vibration Analysis for Civil Structures. (2018)

Una forma de justificar por qué utilizar un método u otro es utilizar el Coeficiente de Relación de Masas (C_m). Javier Sánchez Haro explica en su Tesis “*Desarrollo de teoría sobre impactos. Método simplificado de cálculo de impactos en estructuras*”⁷ [5] este concepto.

$$C_m = \frac{M_p}{M_p + M_e}$$

(1)

Siendo C_m el coeficiente de masas, M_p la masa del proyectil que impacta en la estructura (el excitador) y M_e la masa de la estructura.

En esta Tesis se explica que, si la masa del proyectil es del mismo orden de magnitud que la masa de estructura, la masa del proyectil se integra en la estructura cambiando ligeramente el modo de vibración de esta. El cálculo debe realizarse utilizando el modo fundamental de la estructura ya que es el único que se excita al impacto de dicha masa.

En la *Figura 3.2.* se presenta cada caso estudiado con una curva, cada una de ellas con un color identificativo distinto. Para cada uno de los casos, se indica en el eje de ordenadas el porcentaje de energía absorbida por el modo correspondiente y en el eje de abscisas la relación de masas del modo con el proyectil, identificado con el parámetro “ α ”.

Se puede apreciar de manera clara cómo en todos los casos describen curvas donde el máximo de energía absorbida tiene la tendencia a presentarse en la vertical donde el parámetro “ α ” presenta valores en torno a 1.

Ocurre que el modo con el parámetro “ α ” más próximo a la unidad, es el que tiende a absorber un porcentaje de energía mayor.

A partir de la Figura 3.2. Representación gráfica de la energía cinética en función del coef. de masas en diversos casos de impacto. se aprecia, por tanto, que los modos que más energía absorben presentan los valores de “ α ” más próximos a la unidad que la estructura puede desarrollar. **Dicho de otra manera, en un caso de impacto, los modos que más se excitan son aquellos que tienen la masa equivalente más próxima a la masa del proyectil.**

Los modos que, en el punto de contacto, tienen una masa equivalente mucho mayor a la masa del proyectil, son demasiado lentos para activarse en el impacto, absorbiendo un porcentaje muy pequeño de energía de forma brusca en forma de energía cinética.

⁷ Javier Sánchez Haro. Desarrollo de teoría sobre impactos. Método simplificado de cálculo de impactos en estructuras. Universidad de Cantabria. (2017)

Por el contrario, los modos que en el punto de impacto poseen masa equivalente mucho menor, son rápidos, pero no poseen masa suficiente para detener al proyectil, y por tanto sólo son capaces de absorber muy poca energía.




Figura 3.2. Representación gráfica de la energía cinética en función del coef. de masas en diversos casos de impacto.

Por lo tanto, ante excitadores de masas altas en comparación con la estructura, el modo excitado en servicio será únicamente el primer modo de vibración de la estructura, por lo que se simplifica el estudio de Análisis Modal Experimental frente al Operacional.

3.6 MACHINE LEARNING AND DATA ANALYTICS

El Aprendizaje automático o aprendizaje de máquinas (*Machine Learning*) es una disciplina de la inteligencia artificial que se dedica a desarrollar técnicas que permitan a un programa aprender sobre la experiencia. Lo hace a través de algoritmos, mejora de herramientas, recopilación y análisis de información y más, las plataformas de *Machine Learning* tienen muchas aplicaciones, por ejemplo; el refinamiento y personalización de la interacción entre máquina y usuario y hacer predicciones de comportamiento y clasificación en marketing como la optimización la entrega de publicidad pagada y contenido a las audiencias seleccionadas. En los últimos años, se ha comenzado a aplicar, de igual forma, al mantenimiento y predicción de estado de salud de estructuras.

Se sirve de experiencias y evidencias en forma de datos, con los que comprender por sí mismo patrones o comportamientos. De este modo, puede elaborar predicciones de escenarios o iniciar operaciones que son la solución para una tarea específica.

A partir de un gran número de ejemplos de una situación, puede elaborarse un modelo que puede deducir y generalizar un comportamiento ya observado, y a partir de él realizar predicciones para casos totalmente nuevos. Como ejemplo, se puede considerar la predicción del valor de unas acciones en el futuro según el comportamiento de estas en periodos previos.

Existen **tres tipos principales** de Aprendizaje Automático:

3.6.1 Aprendizaje supervisado

Este tipo de aprendizaje se basa en lo que se conoce como aprendizaje por entrenamiento. Se entrena al sistema proporcionándole cierta cantidad de datos definiéndolos al detalle con etiquetas. Como ejemplo sencillo, proporcionando a la herramienta fotos de perros y gatos con etiquetas que los definen como tales.

Una vez que se le ha proporcionado la suficiente cantidad de dichos datos, podrán introducirse nuevos datos sin necesidad de etiquetas, en base a patrones distintos que ha venido registrando durante el entrenamiento. Este sistema se conoce como clasificación.

Otro método de desarrollo del Aprendizaje Automático consiste en predecir un valor continuo, utilizando parámetros distintos que, combinados en la introducción de nuevos datos, permite predecir un resultado determinado. Este método se conoce como regresión.

Lo que distingue al Aprendizaje Supervisado es que se utilizan distintos ejemplos a partir de los que generalizar para nuevos casos.

3.6.2 Aprendizaje no supervisado

En este tipo de aprendizaje no se usan etiquetas. Estos sistemas tienen como finalidad la comprensión y abstracción de patrones de información de manera directa. Este es un modelo de problema que se conoce como *clustering*. Es un método de entrenamiento más parecido al modo en que los humanos procesan la información.

3.6.3 Aprendizaje por refuerzo

En la técnica de aprendizaje mediante refuerzo, los sistemas aprenden a partir de la experiencia. Como ejemplo se puede observar el comportamiento de un coche autónomo. Cuando el vehículo toma una decisión errónea, es penalizado, dentro de un sistema de registro de valores. Mediante dicho sistema de premios y castigos, el vehículo desarrolla una forma más efectiva de realizar sus tareas.

Es una técnica basada en la prueba y error, y en el uso de funciones de premio que optimizan el comportamiento del sistema. Es una de las maneras más interesantes de aprendizaje para sistemas de inteligencia artificial, pues no requiere de la introducción de gran cantidad de información.

4 METODOLOGÍA

4.1 INTRODUCCIÓN

Los puentes se inspeccionan cada dos años (mantenimiento preventivo), sin embargo, la metodología que se propone se basa en el desarrollo de un sistema de alarmas que se activa cuando la estructura demuestra una respuesta dinámica anómala asociada al paso de trenes sobre la discontinuidad del carril (*bretelle*).

En el siguiente apartado se realiza una presentación de todas las etapas necesarias, desde la toma de datos in situ hasta el procesamiento último para obtener los modelos estadísticos de análisis y diagnóstico.

En el último apartado se planteará una descripción exhaustiva de las fases de postproceso que suceden a la extracción de los parámetros característicos, recogiendo el diseño de una herramienta computacional de detección de daños estructurales basada en el reconocimiento de patrones estadísticos mediante técnicas de aprendizaje no supervisado, que será el órgano de decisión del sistema.

4.2 SISTEMA DE SHM

Diseñar e implementar un sistema efectivo de *SHM* es un proceso que debe realizarse siguiendo una secuencia lógica de pasos y decisiones. Muchas veces, estos sistemas se implantan sin un análisis previo de las necesidades reales, basándose en el deseo de utilizar una tecnología nueva o en seguir las tendencias, pero sin ningún tipo de criterio. Estos, aunque funcionen perfectamente desde el punto de vista técnico, suelen proporcionar información difícil de analizar o que no puede ser usada para fundamentar las decisiones de gestión.

Un sistema de *SHM* eficiente y útil necesita la adquisición de unos conocimientos básicos tanto tecnológicos como socio-organizacionales que puedan integrarse y aplicarse en los distintos componentes del sistema. A continuación, se presentan los pasos fundamentales para lograr una implementación óptima de un sistema de *SHM* en el conjunto estructural, que lo conviertan en una herramienta potente para la evaluación y el control del estado de la estructura.

4.2.1 Sensores

Tal y como se ha explicado en el apartado 3.4.2. *Tipos de sensores y el Capítulo 3.5. ANÁLISIS MODAL OPERACIONAL Y EXPERIMENTAL*, debido al tipo de análisis realizado (*AME*), son necesarios sensores que recojan las vibraciones (aceleraciones) del puente. Estos acelerómetros registran frecuencias en un espectro diferente a los utilizados si el tipo de análisis fuera operacional (*AMO*).

4.2.2 Tratamiento de los datos

Para que los datos se conviertan en información útil, es necesario someterlos a una fase de tratamiento que está formada por cuatro etapas fundamentales:

- **Sincronización:** los datos registrados deben estar sincronizados y ordenados para poder ser analizados. Esto exige que las referencias temporales sean las mismas para todos ellos, y que a cada valor temporal le corresponda un valor del registro. Los grandes conjuntos de datos no existen en un único lugar, sino que tienden a estar repartidos entre múltiples dispositivos, por lo que es necesario tener en cuenta los posibles retardos entre dispositivos a la hora de elegir las frecuencias de muestreo que aseguren una secuencia cronológica de la información. También deberá tenerse en cuenta la disparidad de formatos en que pueden registrarse los datos procedentes de la medición, que puede gestionarse mediante procesos de normalización. En nuestro caso se han sincronizado con el paso de los trenes por la estructura.

- **Exploración:** los sensores generalmente dan multitud de datos y es imprescindible identificar qué variables van a resultar útiles para optimizar el almacenamiento, seleccionando los registros más importantes.

- **Estructuración:** consiste en organizar los datos para que se puedan consultar independientemente del estudio.

- **Procesamiento de señal:** es uno de los elementos más importantes dentro de la fase de tratamiento de datos. Implica dos operaciones, conocidas como normalización y depuración. La normalización será necesaria para simplificar y presentar los datos recogidos bajo condiciones variables, separando los efectos inducidos por posibles daños de aquellos derivados de las condiciones ambientales y operativas. La depuración incluye (i) varios procedimientos para eliminar características indeseadas de los datos como tendencias o ruido; (ii) filtrados y re-muestreos; y (iii) procedimientos de selección de parámetros antes de continuar con el análisis.

El filtrado elimina algunas partes de los datos contenidas dentro de algún rango de frecuencias. Estas operaciones se pueden llevar a cabo en dominios temporales, frecuenciales o espaciales. Algunos filtros pueden usarse también para eliminar el ruido. El re-muestreo suele emplearse para eliminar un rango de frecuencias de los datos registrados. Finalmente, las mediciones de mala calidad que aparezcan como consecuencia de fallos en el montaje de los sensores o en el hardware de adquisición de datos, pueden rechazarse antes o después del procesamiento en base al juicio de expertos. Aquellas mediciones que estén lejos de los valores esperados se denominan valores atípicos, y pueden eliminarse mediante análisis estadísticos.

4.2.3 Extracción de parámetros característicos

Esta parte del proceso de *SHM* consiste en identificar aquella información presente en los datos que permite distinguir de la forma más clara posible el estado no dañado respecto de cualquier situación de daño que pueda experimentar la estructura, limitando las dimensiones de la información utilizada para facilitar las tareas posteriores de identificación del daño. En el Análisis Modal Experimental los parámetros característicos pertenecen al dominio del tiempo y la frecuencia (señales de aceleraciones).

Un parámetro sensible al daño es capaz de proporcionar información útil para la detección de daños a partir de múltiples mediciones de la respuesta estructural. Existen diversos métodos para encontrar estos parámetros, normalmente mediante comparaciones entre modelos analíticos o experimentales que expresen magnitudes comparativas de algunos parámetros del modelo. Por ejemplo, los modelos precisos de elementos finitos pueden emplearse para introducir posibles defectos estructurales mediante simulación computacional, obteniendo la respuesta del sistema dañado, y detectar así qué parámetros son más sensibles a esos daños inducidos.

Existen parámetros simples, como los estadísticos (valor máximo, medio, raíz media cuadrada, etc.), que pueden emplearse para detectar daños graves. Sin embargo, la información para la detección temprana de algunos pequeños daños aún sin desarrollar requiere el empleo de parámetros complejos, obtenidos mediante un procesamiento de señal avanzado. Estos procedimientos pueden dar lugar a simples modelos unidimensionales, como por ejemplo el *Análisis de Componentes Principales*, o bien en algunas representaciones más complejas.

La cantidad de parámetros característicos seleccionados afecta fuertemente a la complejidad de la técnica de detección y a la interpretación de la información, por lo que debe reducirse en la medida de lo posible. Esta tarea puede basarse en el juicio ingenieril de expertos en la materia, aunque existen hoy en día técnicas matemáticas más fiables de reducción dimensional de los datos, como el análisis de componentes principales.

Como resultado de esta fase del proceso de *SHM*, se tendrá un conjunto reducido de datos a partir del cual construir el patrón o referencia para la aplicación del algoritmo de reconocimiento de patrones encargado de asignar un estado a cada medición realizada sobre la estructura.

4.3 EXTRACCIÓN DE SERIES PARA EL DESARROLLO DE POST-PROCESADO DE DATOS

Para realizar el estudio estadístico de los datos obtenidos se utiliza como referencia el artículo “A method for Analysis Linear Correlation for Multi-Sensor of Bridge Monitoring System”⁸ [6] donde se explica con detalle el procedimiento a seguir.

Dependiendo de la naturaleza y el comportamiento de los datos, los métodos estadísticos utilizados serán diferentes. Asumiendo un comportamiento en la zona elástico-lineal de la estructura en N puntos de medición del sistema de monitorización implantado, seleccionando dos cualquiera de dichos puntos de toma de datos se aplica lo siguiente:

Siendo X e Y cada uno de los dos puntos de medida y M las muestras totales recogidas,

$$l_{xx} = \sum_{i=1}^M (x_i - E(X))^2 / (M - 1)$$

(2)

$$l_{yy} = \sum_{i=1}^M (y_i - E(Y))^2 / (M - 1)$$

(3)

$$l_{xy} = \sum_{i=1}^M (x_i - E(X))(y_i - E(Y)) / (M - 1)$$

(4)

Siendo l_{xx} , l_{yy} y l_{xy} las varianzas y covarianza, respectivamente, de dichos puntos de medición. $E(X)$ y $E(Y)$ se corresponden con la expectación media de cada conjunto de datos.

La covarianza puede reflejar el grado de correlación de las dos variables, pero no puede relacionar ese grado de correlación con el resultante de otros puntos de medición. Es necesario un indicador adicional para poder representar los diferentes grados de correlación.

⁸ Zhou Jianting, Yang Jianxi, Wu Diankun. A method for Analysis Linear Correlation for Multi-Sensor of Bridge Monitoring System. (2009)

En el artículo se refiere a este indicador como coeficiente decisivo (*decisive coefficient*) que toma valores entre 0 y 1 y muestra el grado de correlación unitario entre dos secuencias de datos.

$$r' = l_{xy}^2 / l_{xx}l_{yy}$$

(5)

Este coeficiente no muestra, así todo el sentido de la correlación, por lo que es necesario una transformación adicional de los resultados para obtener el parámetro “*r*” que además de mostrar el grado de correlación unitario muestra el sentido de la correlación.

$$r = l_{xy} / \sqrt{l_{xx}l_{yy}}$$

(6)

Cuanto mayor es el valor absoluto de este indicador mayor correlación hay entre las dos variables utilizadas. El método explicado en este apartado se conoce como “*Pearson coefficient models*”. Existen más modelos complementarios a este, dependiendo como se he dicho anteriormente, a la naturaleza de los datos si bien el procedimiento es similar.

Se utilizará este procedimiento para pasar del sistema original de *N* puntos de medida a otro más eficiente que contengan los puntos con una gran correlación, entre sí.

4.4 POST-PROCESADO DE DATOS

3.4.1. Machine Learning

En el ámbito de la detección de daños estructurales, se busca establecer una relación funcional entre los parámetros seleccionados y el estado de la estructura. Dicha correspondencia es difícil de alcanzar por medio de procedimientos de análisis basados en la física y el comportamiento estructural debido a la presencia de gran cantidad de incertidumbres derivadas del diseño, la construcción y el uso. Por lo tanto, es muy frecuente recurrir al uso de modelos estadísticos que permitan detectar la presencia de daños a partir de técnicas de aprendizaje automático o *Machine Learning*.

El **aprendizaje automático** es una rama de conocimiento que consiste en construir relaciones computacionales entre ciertas magnitudes en base a los datos observados. El algoritmo aprende las reglas computacionales a partir de una evidencia observacional que le permite tomar decisiones. Todos estos algoritmos se encargan de analizar distribuciones estadísticas de las

mediciones de los parámetros, y pueden agruparse en las tres categorías siguientes según el problema a resolver:

Clasificación: el resultado del algoritmo es una etiqueta o estado dentro de un conjunto discreto de posibilidades. Para aplicar esta técnica de forma más general, se deben delimitar todos los posibles estados. Esto quiere decir que, para la localización del daño, la estructura debe dividirse en varias subestructuras, de modo que el algoritmo podrá asignar el daño a una determinada subestructura. Este tipo de algoritmos resulta útil en el sentido de que proporcionan información sobre la probabilidad de pertenencia a cada una de las clases, lo que aporta un nivel de confianza aplicable al diagnóstico.

Regresión: este algoritmo proporciona como resultado una o más variables continuas con las que relacionar las mediciones reales.

- **Detección de anomalías:** el resultado del algoritmo será una indicación de la presencia de datos atípicos en el registro continuo de la monitorización, que podrá ser valorado como un potencial daño presente en la estructura. En este caso, al algoritmo solo se le exige indicar si los datos de entrada provienen de una condición de operación normal o no. Se trata del problema de clasificación más simple, ya que solo tiene que distinguir entre dos clases o estados.

En función de la información disponible en el sistema de *SHM*, los algoritmos de *Machine Learning* pueden clasificarse en dos grandes grupos: algoritmos de aprendizaje supervisado y algoritmos de aprendizaje no supervisado:

- **Aprendizaje supervisado:** estas técnicas requieren la alimentación del algoritmo con las sucesivas muestras de datos relativas a cada uno de los estados de deterioro posibles conocidos, y se van modificando hasta que la salida coincide con las etiquetas de referencia. Se emplean para alcanzar los niveles más elevados de identificación del daño y son difíciles de implementar por la gran cantidad de información que necesitan.

- **Aprendizaje no supervisado:** estas metodologías se limitan a proporcionar un nivel de conocimiento muy básico en la jerarquía de identificación del daño. Su principal ventaja es que solo necesitan información sobre el estado no dañado (de referencia) de la estructura para poder implementarse.

La detección de daños consiste en asignar una etiqueta clasificatoria a un conjunto de mediciones de entrada que las relacione con un cierto estado de daño de la estructura, por

lo que se corresponde con un problema de clasificación. La técnica de aprendizaje automático normalmente empleada para la resolución de los problemas de clasificación se conoce como “*Reconocimiento de Patrones Estadísticos*” y será descrita en detalle en el siguiente apartado.

Por tanto, el desarrollo de modelos estadísticos es un paso esencial en un sistema de *SHM*, ya que constituye el punto de partida de la generación de algoritmos que trabajen sobre los parámetros característicos extraídos para evaluar el estado estructural y detectar la presencia de daños. Analizando las respuestas del sistema, el ingeniero será capaz de identificar la existencia de alguno de los riesgos previstos, o si se han materializado signos de degradación en la estructura. Además, el propietario también será capaz de establecer protocolos de actuación que respondan a tiempo ante la detección temprana de defectos.

3.4.2. Comparación de Modelos de Regresión de ML

Existen múltiples modelos de regresión basados en diferentes técnicas y algoritmos. En este apartado se explicarán y compararán algunas de ellas. El parámetro principal que utilizaremos para medir el comportamiento de cada modelo es el estadístico “ R^2 ”.

- **Regresión Lineal:** Es el modelo más básico, es una aproximación que relaciona una variable dependiente con una o más variables explicativas.
- **K-Neighbors:** Este es un método de clasificación no paramétrico, que estima el valor de la función de densidad de probabilidad o directamente la probabilidad a posteriori de que un elemento pertenezca a la clase específica a partir de la información proporcionada por el conjunto de prototipos. En el proceso de aprendizaje no se hace ninguna suposición acerca de la distribución de las variables predictoras.
- **Árboles de Decisión:** Aprendizaje basado en árboles de decisión utiliza un árbol de decisión como un modelo predictivo que mapea observaciones sobre un artículo a conclusiones sobre el valor objetivo del artículo. Es uno de los enfoques de modelado predictivo utilizadas en estadísticas, minería de datos y aprendizaje automático. Los modelos de árbol, donde la variable de destino puede tomar un conjunto finito de valores se denominan árboles de clasificación. En estas estructuras de árbol, las hojas representan etiquetas de clase y las ramas representan las conjunciones de características que conducen a esas etiquetas de clase. Los árboles de decisión, donde la variable de destino puede tomar valores continuos (por lo general números reales) se llaman árboles de regresión.

- **Boosting Methods:** *Boosting* es un meta-algoritmo de aprendizaje automático que reduce el sesgo y varianza en un contexto de aprendizaje supervisado. *Boosting* está basado en el cuestionamiento planteado: ¿Puede un conjunto de clasificadores débiles crear un clasificador robusto? Un clasificador débil está definido para ser un clasificador el cual está solo débilmente correlacionado con la clasificación correcta (el mismo clasifica mejor que un clasificador aleatorio). En contraste, un clasificador robusto es un clasificador que tiene un mejor desempeño que el de un clasificador débil, ya que sus clasificaciones se aproximan más a las verdaderas clases.

3.4.3. Gradient Boosting

Combina las técnicas de Árboles de Decisión con algoritmos tipo *Boosting* para crear el número óptimo de árboles. Predicciones robustas y con una precisión similar a la de otros modelos. *Gradient boosting* o Potenciación del gradiente, es una técnica de aprendizaje automático utilizado para el análisis de la regresión y para problemas de clasificación estadística, el cual produce un modelo predictivo en forma de un conjunto de modelos de predicción débiles, típicamente árboles de decisión. Construye el modelo de forma escalonada como lo hacen otros métodos de *boosting*, y los generaliza permitiendo la optimización arbitraria de una función de pérdida diferenciable. La idea de la potenciación del gradiente fue originada en la observación realizada por Leo Breiman⁹ [7] en donde el *Boosting* puede ser interpretado como un algoritmo de optimización en una función de coste adecuada. Posteriormente Jerome H. Friedman¹⁰ [8] ¹¹ [9] desarrolló algoritmos de aumento de gradiente de regresión explícita, simultáneamente con la perspectiva más general de potenciación del gradiente funcional de Llew Mason, Jonathan Baxter, Peter Bartlett y Marcus Frean¹² [10] ¹³ [11]. En sus últimos dos trabajos presentaron la visión abstracta de los algoritmos de potenciación como algoritmos iterativos de descenso de gradientes funcionales. Es decir, algoritmos que optimizan una función de coste sobre el espacio de función mediante la elección iterativa de una función (hipótesis débil) que apunta en la dirección del gradiente negativo. Esta visión de gradiente funcional de potenciación ha llevado al desarrollo de algoritmos de potenciación en muchas áreas del aprendizaje automático y estadísticas más allá de la regresión y la clasificación.

⁹ Breiman, L. *Arcing The Edge* (1997)

¹⁰ Friedman, J. H. Greedy Function Approximation: A Gradient Boosting Machine. (1999)

¹¹ Friedman, J. H. Stochastic Gradient Boosting. (March 1999)

¹² Mason, L.; Baxter, J.; Bartlett, P. L.; Frean, Marcus (1999). Boosting Algorithms as Gradient Descent». S.A. Solla and T.K. Leen and K. Müller, ed. Advances in Neural Information Processing Systems.

¹³ Mason, L.; Baxter, J.; Bartlett, P. L.; Frean, Marcus (1999). Boosting Algorithms as Gradient Descent in Function Space.

Gradient tree boosting

Gradient boosting se suele utilizar combinado con Árboles de Decisión (especialmente con el Método CART) con un tamaño fijado. Para este caso concreto, Friedman propone una modificación en el método *Gradient Boosting* que mejora el rendimiento de aprendizaje.

4.5 VALIDACIÓN DE HERRAMIENTA

Una vez se ha definido el modelo estadístico de referencia y establecido el límite de aceptación, el siguiente paso para la configuración de la herramienta de detección de anomalías consiste en verificar su correcto funcionamiento con otro conjunto de datos que constituyen la muestra de verificación. La característica fundamental de estos datos reside en que se conoce el estado de la clasificación al que pertenecen, por lo que permitirán entrenar al algoritmo para que realice los diagnósticos correctos.

Obtención de la muestra de validación

Para confirmar que la herramienta realiza diagnósticos acertados, se le deben introducir nuevos datos procedentes del estado no dañado de la estructura, de manera que cualquier indicación de fallo que proporcione será automáticamente asociada a una falsa alarma. La muestra de validación puede obtenerse de un proceso de monitorización anterior, asegurando que los datos proceden de la condición normal mediante un tratamiento similar al de la muestra de referencia.

Si esta información no estuviera disponible, es posible generarla por medio de simulación computacional. La simulación consiste en efectuar muestreos aleatorios sobre una función de probabilidad continua que represente a la población de estudio. Este procedimiento está basado en técnicas de Montecarlo¹⁴ [12] .

Debe restringirse la amplitud del muestreo a aquellas zonas de mayor probabilidad de la función de distribución, para evitar que se tomen datos susceptibles de generar falsas alarmas.

Hay que tener en cuenta que en el ámbito de la *SHM* generalmente se dispondrá de series de datos multivariados, debido al empleo de varios sensores para la adquisición de datos. Las mediciones realizadas durante un proceso de monitorización por cada uno de los sensores guardarán ciertas correlaciones entre sí, las cuales deben conservarse en la muestra de validación. Por ello, el muestreo aleatorio es útil para generar los datos correspondientes a uno de los sensores, pero para disponer del conjunto completo y sincronizado de datos de validación,

¹⁴ Peña Sánchez de Rivera, Daniel. Deducción de distribuciones: el método de Monte Carlo, en *Fundamentos de Estadística*. (2001)

deben obtenerse los registros de los demás sensores por medio de la información de las correlaciones en la muestra de referencia. Esta técnica permitirá, en caso de que en una monitorización real se estropeen algunos de los sensores, completar la información mediante los datos registrados por al menos uno de los sensores en buen estado.

5 CASO DE ESTUDIO

5.1 INTRODUCCIÓN

La idea principal para llevar a cabo este proyecto surge con el objetivo de continuar mejorando los algoritmos de *Machine Learning* como sistemas predictivos de daño. Necesitamos elaborar una herramienta de detección de anomalías basada en la respuesta dinámica de la estructura a las sollicitaciones dinámicas de los trenes al paso de la discontinuidad del carril (*bretelle*). Para ello se utilizarán los datos almacenados en labores de monitorización y, tal y como se describió en el Capítulo 4. *METODOLOGÍA* de este trabajo, se recurre a las técnicas de reconocimiento de patrones estadísticos, que permiten resolver un problema de clasificación simple entre dos estados posibles: el dañado y el no dañado.

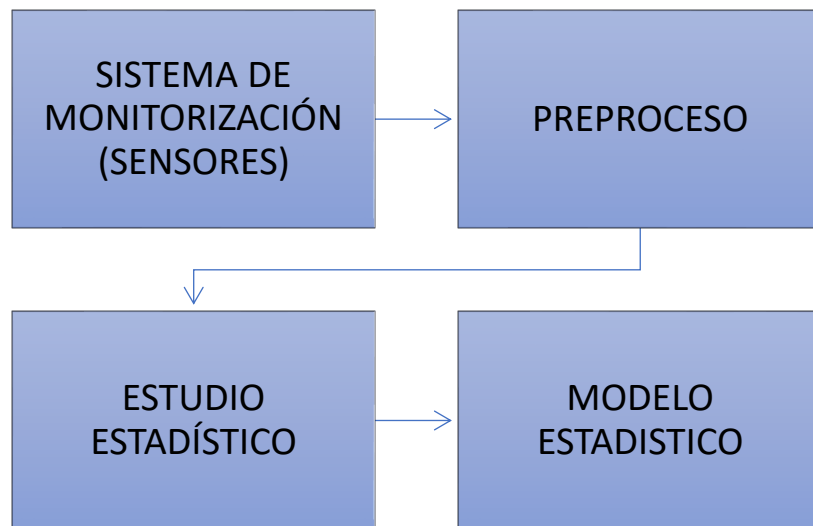


Figura 5.1. Etapas de elaboración de un SHM

En este capítulo se describirán todas las etapas llevadas a cabo para el cálculo e implementación del sistema *SHM*. El proyecto abarca desde la etapa de recogida de datos de los sensores (preproceso) hasta la elaboración del modelo estadístico llevado a cabo mediante algoritmos de reconocimiento de patrones estadísticos (Figura 5.1.).

El puente objeto de estudio presenta un punto de gran interés en su estructura: un aparato de vía (tipo *bretelle*) sobre su traza (Figura 5.2), lo cual es inusual por implicar riesgo de amplificar la respuesta dinámica del puente ante un mal funcionamiento o reglaje de dicho aparato.




Figura 5.2. Ejemplo de aparato de dilatación de vía (bretelle).

5.2 DESCRIPCIÓN DE LA ESTRUCTURA

El viaducto de Bolueta (Bilbao)¹⁵ [13], se encaja en una curva de acuerdo vertical y en planta. Este viaducto tiene un diseño estructural poco convencional y, además, tiene un dispositivo de vía (*bretelle* o diagonal doble) ubicado en uno de los vanos centrales. Debido a esto, es un punto de gran interés para estudiar el comportamiento dinámico de la estructura al paso de trenes. Las principales características del puente se muestran en la Figura 5.3.

¹⁵ David García, Ignacio Piñero, Sergio Pérez, Aratz García. The Value of Structural Health Monitoring for the reliable Bridge Management. (2017)




Figura 5.3. Descripción de la estructura (puente de Bouleta, Bilbao).

El puente fue construido en 2002 y está hecho de hormigón armado y pretensado. Consta de 5 vanos ($22\text{m} + 3 \times 24,5\text{m} + 24\text{m}$) que se conectan a un doble arco sobre el río Nervión de 63 metros de largo y un tramo corto (19,5 m) permitiendo la transición a un túnel muy cercano. Los muelles tienen forma de V y están conectados monolíticamente a la cubierta. Los rodamientos se encuentran en el nivel de tránsito.

Además, los arcos se fijan tanto en extremos como las pilas inclinadas se fijan a la cubierta y los pies. Por último, es necesario mencionar que el punto fijo contra las fuerzas horizontales (longitudinal y transversal) se encuentra en el centro de longitud del arco.

5.3 OBJETIVO

El punto de interés de la estructura se encuentra en lugar indicado en la imagen (recuadro rojo). Esta zona presenta un aparato de dilatación de vía. Es el punto de estudio y donde, una vez concluida la monitorización para el análisis, se monitorizará de forma permanente la estructura.

La etapa de instrumentación se llevó a cabo en 3 fases distintas, donde los acelerómetros fueron reubicados en posiciones diferentes del puente. En cada fase fueron colocados 8 acelerómetros, de cuales 2 de ellos no variarán su posición, nos referiremos a ellos como acelerómetros fijos. Estos acelerómetros están colocados en el punto de interés de la estructura.

El resto (6) varían su posición dependiendo de cada fase de medición. Además, se dispone de sensores de temperatura y humedad. En la *Figura 5.4.* se muestra la localización exacta de los aparatos.

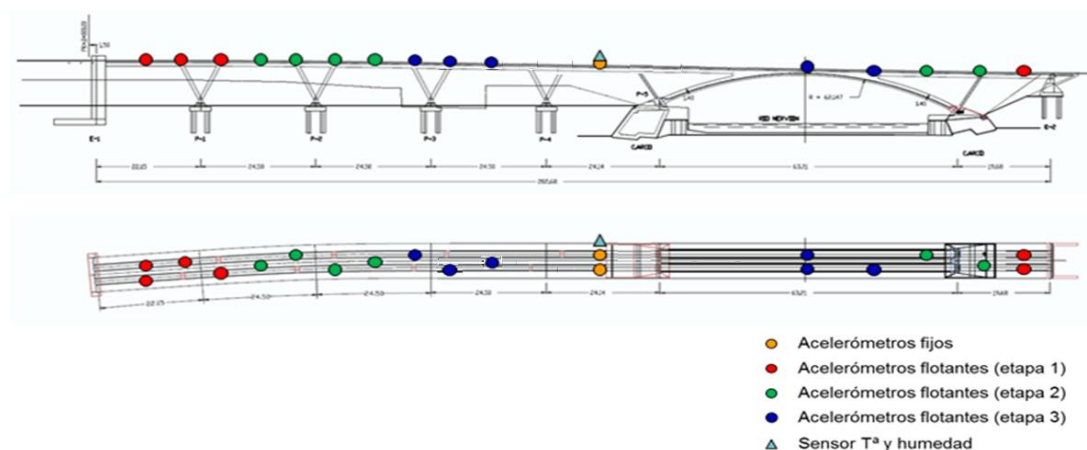


Figura 5.4. Esquema de colocación de acelerómetros y fases de medición.

El objetivo del presente estudio es elaborar un sistema de alarmas basado en un modelo estadístico lo suficientemente robusto como para, a partir de las señales monitorizadas por los acelerómetros fijos, poder inferir el comportamiento en el resto del puente sin necesidad de colocar aparatos en todos los puntos.

El sistema de alarmas se basa en el grado de correlación entre acelerómetros fijos y variables.

5.4 SISTEMA DE MONITORIZACIÓN

Los sistemas de instrumentación consisten en 8 acelerómetros (3 ejes), 2 clinómetros (2 ejes) y sensores de temperatura y humedad. Se han utilizado dos receptores de datos con 16 canales de entrada para la recogida de información. Como equipo de alimentación se instalaron paneles solares como complemento a la fuente de alimentación. Los datos recogidos son enviados a un servidor central (*ftp*) por medio de un *router* 4G. La información se organizó en paquetes de eventos de 10 minutos teniendo en cuenta el horario de uso de la estructura.

Las señales eléctricas procedentes de los diferentes sensores, una vez que se estabiliza la señal es enviada a dos receptores que procesan la señal mediante el sistema *CATMAN* (software

diseñado por *HBM*). *CATMAN* procesa la señal de los acelerómetros (m/s^2), y los sensores de humedad (%) y temperatura ($^{\circ}C$) y envía los datos al servidor (*ftp*).

Inicialmente se realizan un total de 195 mediciones repartidas durante el día en función de los horarios de uso de la estructura. Cada medición registra datos de aceleraciones en cada uno de los ejes (X,Y,Z) durante 600 segundos. Las 195 mediciones se han repartido en 3 etapas dejando 2 acelerómetros fijos y cambiando de posición el resto, tal y como se ha detallado en el apartado **5.2.DESCRIPCIÓN DE LA ESTRUCTURA**. Este reparto se ha realizado de manera que la primera etapa consta de 29 mediciones, la segunda 140 y el resto (26) la última etapa.

La frecuencia de muestreo es de 100 Hz, es decir, en cada medición se registran 60000 muestras discretas de las aceleraciones sufridas por la estructura. Los sensores de temperatura y humedad por su parte recogen una muestra por medición, obteniendo así 195 muestras totales.

El número de muestras de partida son, por tanto, $60000 \times 8 \times 3 \times 195 = 280.800.000$

5.5 PREPROCESO

En este apartado se detallarán los diferentes filtrados y soluciones adoptadas para obtener las frecuencias principales de la estructura.

Debido al volumen excesivo de datos de partida es necesario un estudio estadístico de los datos de manera que seamos capaces de reducir la cantidad de información con la que trabajar. Selección de acelerómetros y limpieza de datos

En un primer estudio realizado de las mediciones se pretende desechar aquellos acelerómetros cuya medición no es correcta. Para ello se representará cada medición de cada fase (X,Y,Z) de cada acelerómetro en función del tiempo.

Debido a que las mediciones se han tomado de acuerdo con el horario de uso del puente, se esperan resultados con un ruido de fondo de la estructura interrumpido por impulsos introducidos por el paso de vehículos (en este caso trenes) a lo largo de la estructura. La amplitud y duración de estos impulsos (picos) variarán dependiendo de la posición del acelerómetro en el puente y del tipo de medida que realiza (X,Y,Z)

Los criterios seguidos para realizar esta tarea son los siguientes:

- Se considerará medida fallida aquella medición donde al menos 1 de las 3 componentes del acelerómetro registre un valor erróneo.
- Aquellas representaciones que no se ajusten a la forma de la función esperada (picos en el paso de trenes y ruido de fondo).

- Componente aceleración creciente en el tiempo.
- Medida ilegible.
- Valores discordantes con el resto de los acelerómetros para esa medida.

La *Figura 5.5.* muestra una serie de mediciones descartadas.

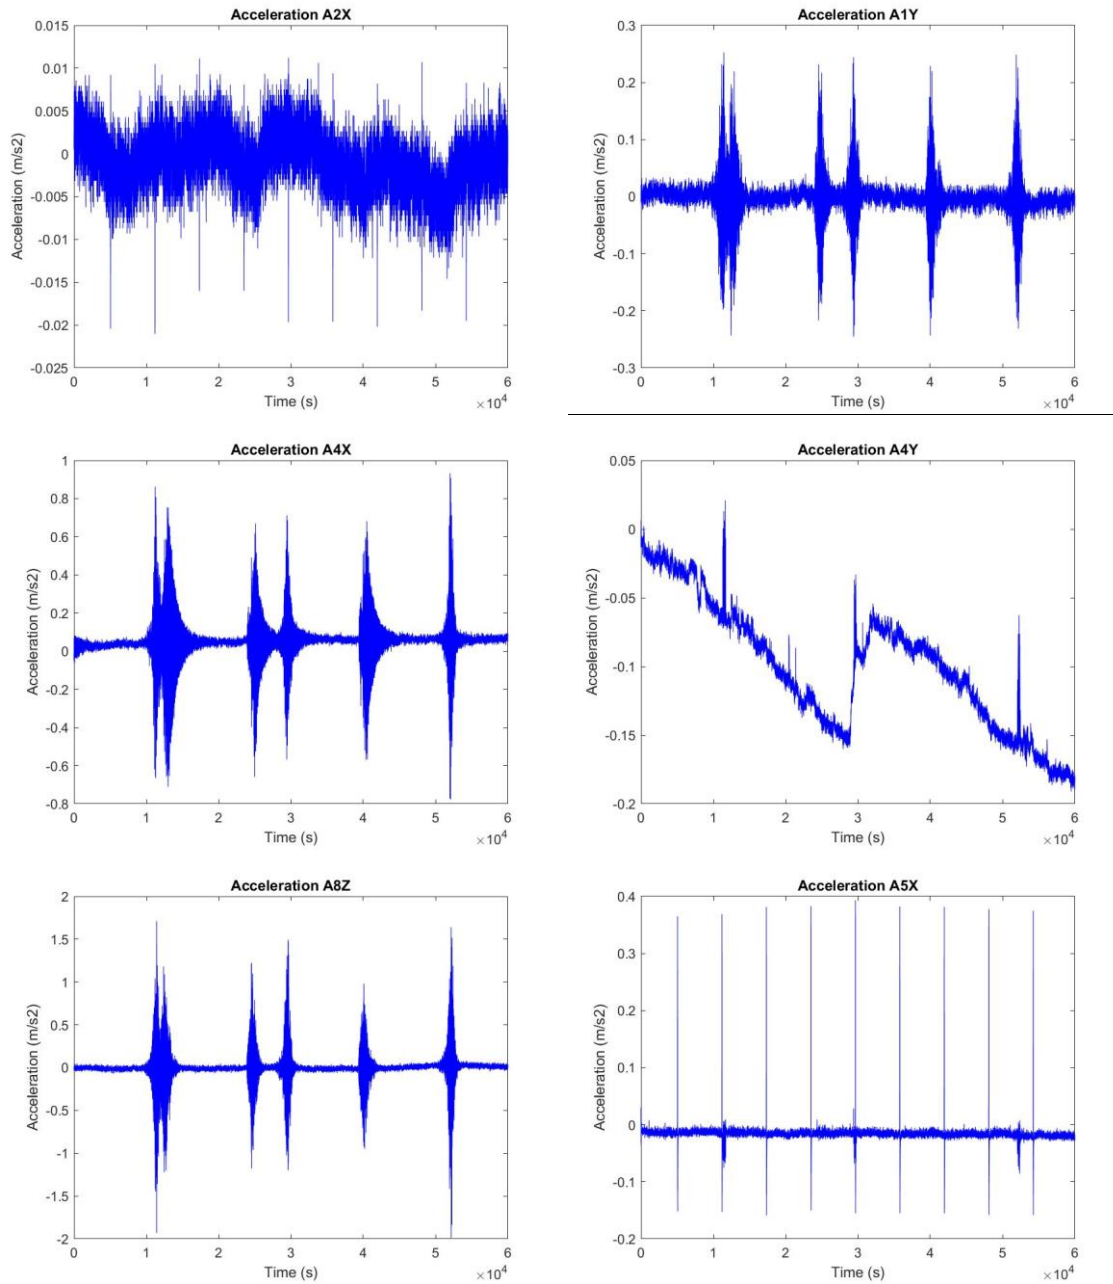


Figura 5.5. Ejemplos de medidas no válidas.

Una vez realizada esta tarea, se registró el estado del acelerómetro en esa medida. La tabla creada por estos registros sirvió para el cálculo posterior de las frecuencias de la estructura. La *Figura 5.6.* muestra un extracto de la tabla utilizada para filtrar.

	ACELERÓMETROS								FASE
	AC. 1	AC. 2	AC. 3	AC. 4	AC. 5	AC. 6	AC. 7	AC. 8	
MEDIDA 001	1	1	1	1	0	1	1	1	1
MEDIDA 002	1	0	1	1	0	1	1	1	1
MEDIDA 003	0	0	0	0	0	0	0	0	1
MEDIDA 004	0	0	0	0	0	0	0	0	1
MEDIDA 005	1	1	1	1	0	1	1	1	1
MEDIDA 006	0	0	0	0	0	0	0	0	1
MEDIDA 007	1	1	0	1	0	0	1	0	1
MEDIDA 008	1	0	1	1	0	0	1	0	1
MEDIDA 009	1	0	1	1	0	1	1	1	1
MEDIDA 010	1	1	1	1	0	1	1	1	1

Figura 5.6.Extracto de Limpieza de acelerómetros.

Esta tabla de “Acelerómetro Válidos” nos permite automatizar el método de trabajo, ignorando las mediciones erróneas.

Una vez aplicado este primer filtrado se procedió a eliminar el error del propio equipo de medida. Este error hace referencia a una componente cuasi-lineal y creciente en la medición.

La diferencia entre este filtrado y el realizado en el paso anterior es que la componente de error del aparato no se puede apreciar a simple vista. Este es el motivo por el que, si la tendencia creciente de la medida se aprecia de forma significativa a simple vista, no se debe al error introducido por el aparato, y se considera un medida errónea y por lo tanto desechada.

5.5.1 Selección de muestra y periodos temporales

Para obtener las frecuencias naturales de la estructura se estudiará el comportamiento del puente sometido a vibraciones libres, es decir, la respuesta del puente una vez cesa la carga o sollicitación (cuando el tren ha abandonado el puente). Esta respuesta en vibraciones libres se corresponde con el tramo de señal desde el máximo local (pico) hasta el amortiguamiento e integración con el ruido de fondo.

Se utilizará un algoritmo de detección de picos mediante el cual se divide cada medida en diferentes tramos. Estos tramos abarcan las muestras comprendidas entre cada máximo local y el amortiguamiento de la respuesta en vibraciones libres.

Dicho algoritmo se implementó en la herramienta Matlab que aplica el cálculo de picos a cada componente de cada acelerómetro y a cada una de las 195 medidas registradas. Se añadirá en

el algoritmo lógica proposicional de manera que se evitarán aquellas medidas desechadas por la matriz de Acelerómetros Válidos.

Una vez aplicado el algoritmo de detección de picos, tendremos tramos de señal, todavía en función del tiempo con una forma tipo, mostrada en la *Figura 5.7*.

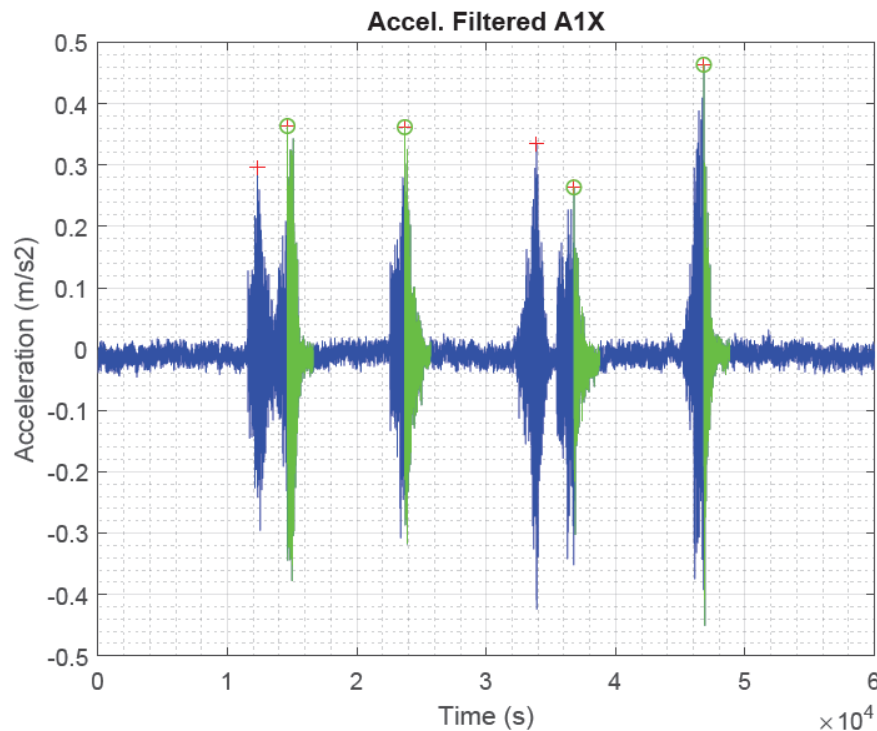


Figura 5.7: Cálculo de picos y tramos de estudio (verde)

Se necesita estudiar la respuesta en vibraciones libres, para ello, es necesario tener la respuesta completa a la excitación, de manera que se han eliminado los picos muy próximos entre sí, utilizando únicamente el segundo de ellos.

En definitiva, se utilizarán tramos completos de señal, desde el pico hasta el amortiguamiento y se trabajará, de ahora en adelante con las muestras en color verde (*Figura 5.7*) respecto a las originales en azul.

5.5.2 Dominio de la frecuencia: Análisis de Fourier

Una vez que se dispone de las muestras de interés ya depurados y filtrados se procede al cálculo de las frecuencias principales de la estructura asociadas a esa excitación. El código completo se muestra en el *ANEXO I: SCRIPTS UTILIZADOS* y, a continuación, aparecen recogidas las frecuencias obtenidas para una medición (*Tabla 5.1*).

Tabla 5.1. Frecuencias obtenidas y valores de Temperatura y Humedad.

	Frec. 1º (Hz)	Frec. 2º (Hz)	Frec. 3º (Hz)	Tº(C)	Humedad (%)
A1X	6.5462	6.5217	6.4729	2.7570	0.7534
A1Y	6.4729	6.4485	6.4729	2.7570	0.7534
A1Z	5.9355	5.9111	4.7631	2.7570	0.7534
A2X	6.5462	6.5217	6.4729	2.7570	0.7534
A2Y	6.5217	6.4485	6.3019	2.7570	0.7534
A2Z	5.7890	5.9355	5.8867	2.7570	0.7534
A3X	6.5217	6.5217	6.5462	2.7570	0.7534
A3Y	6.3752	6.4485	6.3508	2.7570	0.7534
A3Z	6.3263	6.3508	5.5447	2.7570	0.7534
A4X	3.2731	4.4455	3.0532	2.7570	0.7534
A4Y	6.4240	6.3996	6.3263	2.7570	0.7534
A4Z	6.1798	5.3249	5.8378	2.7570	0.7534
A5X	0	0	0	2.7570	0.7534
A5Y	0	0	0	2.7570	0.7534
A5Z	0	0	0	2.7570	0.7534
A6X	8.9888	6.2286	8.9643	2.7570	0.7534
A6Y	2.3937	2.4182	2.3937	2.7570	0.7534
A6Z	5.8867	5.8622	5.9111	2.7570	0.7534
A7X	6.4729	6.4729	6.3019	2.7570	0.7534
A7Y	2.3937	2.4182	2.3693	2.7570	0.7534
A7Z	5.8867	5.9355	5.8134	2.7570	0.7534
A8X	2.3937	2.4182	2.3693	2.7570	0.7534
A8Y	6.3752	6.4485	6.3263	2.7570	0.7534
A8Z	5.7890	5.6668	7.6942	2.7570	0.7534

5.5.3 Resultados

En este apartado se detallan los datos tratados y listos para realizar el estudio estadístico. Los outputs obtenidos correspondientes a toda la etapa de preproceso muestran las 3 primeras frecuencias de cada medida realizada. Estos datos están almacenados en una matriz (fichero de salida de Matlab) de dimensiones 24 x 3 para cada medición. En total se dispone de 195 Matrices de Frecuencias.

El código utilizado ha permitido extraer las 3 primeras frecuencias de la estructura, aunque de ahora en adelante se trabajará únicamente con la primera frecuencia. Esta simplificación se ha realizado teniendo en cuenta la naturaleza de la estructura las cargas aplicadas.

Teniendo en cuenta la rigidez de este tipo de estructuras y la frecuencia de excitación de las cargas, el modo de vibración que aparece o que se verá afectado será, casi exclusivamente, el

primer modo de vibración. Debido a esto, se justifica estructuralmente la aproximación del estudio estadístico al primer modo de vibración.

En esta etapa de preproceso, por lo tanto, se han seleccionado los acelerómetros con mediciones correctas, se han filtrado dichos acelerómetros utilizando un filtro paso banda tipo *Butterworth* y se han calculado las frecuencias principales para cada medida mediante análisis de Fourier. Se ha reducido el volumen de datos de trabajo sin perder información relevante en el proceso.

A continuación, se realizará un estudio estadístico con las 195 Matrices de Frecuencias (24x3).

5.6 ESTUDIO ESTADISTICO

5.6.1 Introducción

En esta etapa se aborda la extracción de series para el posterior desarrollo del modelo estadístico. El estudio estadístico permite aprovechar la información obtenida en el proceso de monitorización para evaluar el estado de la estructura. De acuerdo con el enfoque planteado en la tesis de David García Sánchez [1] se propone la matriz de correlaciones (o covarianzas) como punto de partida para desarrollar una herramienta de diagnóstico global sobre el estado de la estructura. Utilizando dicha matriz se aplicará el método explicado en el Capítulo 4.3 *EXTRACCIÓN DE SERIES PARA EL DESARROLLO DE POST-PROCESADO DE DATOS*.

5.6.2 Objetivo

Partiendo de los datos procesados y de las Matrices de Frecuencias obtenidas en las 195 mediciones (3 fases de medición) se pretende seleccionar aquellos puntos de medición robustos. Como ya se ha explicado en el apartado 5.2. *DESCRIPCIÓN DE LA ESTRUCTURA*, los acelerómetros variables miden desde posiciones diferentes del puente. El objetivo del presente estudio es encontrar aquellos puntos que registran datos con una relación mayor respecto a los acelerómetros fijos de la estructura. En definitiva, poder establecer una monitorización *soft-sensing* de la estructura.

5.6.3 Análisis de correlación lineal

El proceso de monitorización proporciona una muestra de datos que se corresponden con el estado no dañado de la estructura (procedimientos de aprendizaje automático no supervisado). En este tipo de estudios es recomendable la normalización de los datos, sobre todo cuando se trabaja con sensores de distinta naturaleza. En este caso no será necesario dicha normalización ya que los sensores son del mismo tipo. Además, se trabajará de forma

independiente con cada componente de los datos tratados, es decir, los 3 ejes de aceleraciones (X,Y,Z) no se relacionarán entre sí.

El procedimiento, por tanto, pasa por calcular los valores de varianza y covarianza de los acelerómetros variables respecto a los fijos, resultando matrices de covarianzas para cada componente (X,Y,Z) de cada frecuencia principal (1º,2º,3º) de las 3 fases de medición para cada acelerómetro fijo colocado.

La matriz de covarianzas se ha planteado de la siguiente forma:

Dos puntos diferentes de medición, por un lado, los acelerómetros fijos y, por otro, los variables. De esta manera, se aplicarán las ecuaciones siguientes para el cálculo de la matriz de covarianzas.

Considerando los dos puntos de medida explicados y siendo M el número total de muestras, las expresiones detalladas en el *Capítulo 4.METODOLOGÍA* para el caso concreto de estudio resultan las siguientes expresiones:

$$\sigma_{A1XA1X} = \sum_{i=1}^M (A1X_i - E(A1X))^2 / (M - 1)$$

(7)

$$\sigma_{A7XA7X} = \sum_{i=1}^M (A7X_i - E(A7X))^2 / (M - 1)$$

(8)

$$\sigma_{A1XA7X} = \sum_{i=1}^M (A1X_i - E(A1X))(A7X_i - E(A7X)) / (M - 1)$$

(9)

$$M\sigma = \begin{pmatrix} \sigma_{A1XA1X} & \sigma_{A1XA7X} \\ \sigma_{A1XA7X} & \sigma_{A7XA7X} \end{pmatrix}$$

(10)

$$r = \sigma_{A1XA7X}^2 / \sigma_{A1XA1X} \sigma_{A7XA7X}$$

(11)

$$R = \sigma_{A1XA7X} / \sqrt{\sigma_{A1XA1X} \sigma_{A7XA7X}}$$

(12)

Donde, $E(A\#X)$ es la media aritmética del acelerómetro en cuestión. Los valores de las muestras son los valores de frecuencia obtenidos en el preproceso de los datos. Es decir, se trabajan con una muestra de 195 valores repartidos en 3 etapas de medición.

Las ecuaciones anteriores muestran la matriz de covarianzas en la relación del acelerómetro A1 (variable) con el A7 (fijo), y más concretamente la componente X. Se obtendrá un valor r y R de esta componente siendo necesario obtener los correspondientes en los ejes Y y Z. De esta manera se obtienen los parámetros “ r ” y “ R ” para cada componente de acelerómetro variable que recogen el grado de correlación entre dicho acelerómetro variable y el fijo. Como se disponen de dos acelerómetros fijos, se procederá de forma análoga con el sensor restante. En la *Figura 5.8. Relaciones de Acelerómetros* muestran las relaciones entre los acelerómetros.

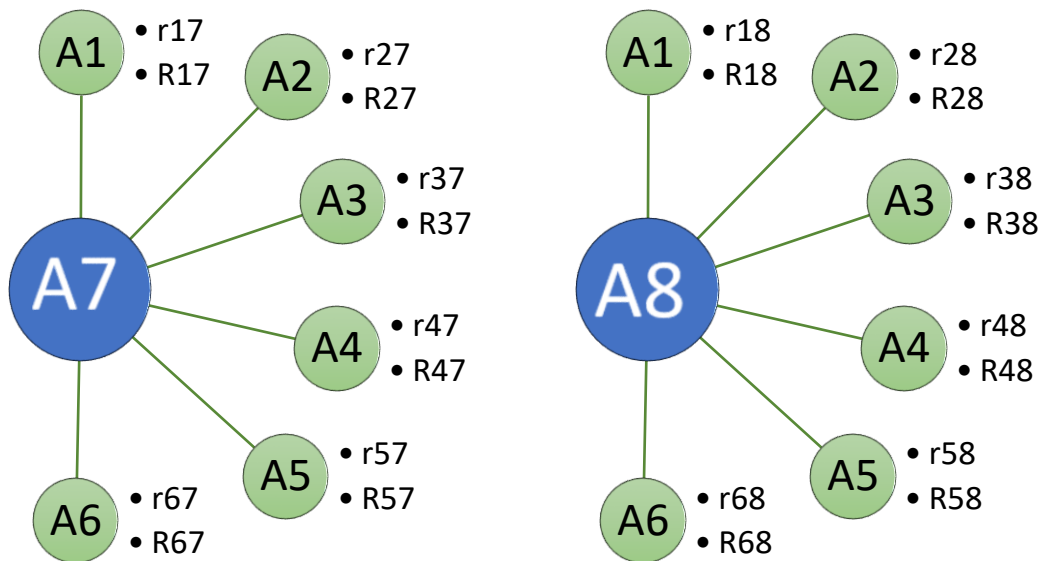


Figura 5.8. Relaciones de Acelerómetros

Este método se ha explicado para la fase 1 de medición y para la frecuencia principal, pero se han obtenido los resultados pertinentes para las fases 2 y 3 y las 2ª y 3ª frecuencia-

El código y los resultados completos de este análisis se muestran en el *ANEXO I: SCRIPTS UTILIZADOS*.

A continuación, se muestran los valores más importantes obtenidos en el proceso. Los valores que aparecen en las *Figuras*Figura 5.9 y *Figura* 5.10 representan el grado de correlación existente entre los acelerómetros variables y cada uno de los fijos (A7 y A8). En caso de obtener un valor cercano a la unidad quiere decir que los valores de frecuencias naturales de las mediciones se corresponden prácticamente al 100%, mientras que si el valor es próximo a cero significa que la relación es nula.

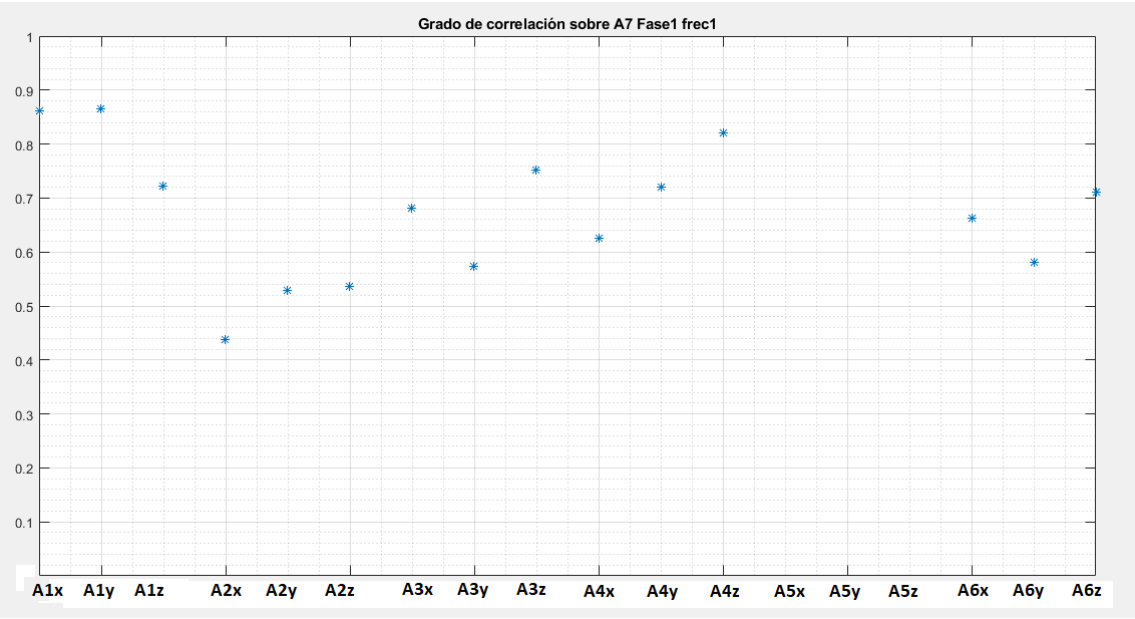


Figura 5.9. Grados de correlación sobre A7




Figura 5.10. Grados de correlación sobre A8

5.7 MODELO PREDICTIVO

5.7.1 Introducción

En este capítulo se aborda el diseño de los modelos predictivos que permiten aprovechar la información disponible del proceso de monitorización y el estudio estadístico para evaluar el estado de la estructura. De acuerdo con el procedimiento desarrollado en el Capítulo 4. METODOLOGÍA, utilizando técnicas de aprendizaje automático y mejora continua se configurará un algoritmo de permitirá clasificar la estructura entre dos estados (dañado y no dañado).

Por tanto, de acuerdo con este enfoque, se aplicará el procedimiento desarrollado en el apartado 4.4. POST-PROCESADO DE DATOS para configurar un algoritmo de clasificación entre dos estados (dañado y no dañado) que permita valorar el estado de la estructura a nivel global prácticamente en tiempo real. Dicho procedimiento está basado en las técnicas de aprendizaje automático no supervisado, al disponerse únicamente de datos correspondientes al estado no dañado de la estructura. La herramienta se ha diseñado mediante el entorno gratuito de *Jupyter Notebook “Colaboratory”*.

5.7.2 Selección de acelerómetros: Grado de correlación

Partiendo de los datos obtenidos en el estudio estadístico estableceremos un nivel de confianza a partir del cual se puede afirmar que la correlación entre los acelerómetros variables y fijos es suficientemente alta y se mantiene constante. En la *Tabla 5.2. Correlaciones* se muestran los valores de “R” obtenidos en el estudio estadístico. En rojo aparecen valores nulos, lo cual quiere decir que no se disponen de datos de ese acelerómetro en esa fase.

Tabla 5.2. Correlaciones

	<u>ACELERÓMETRO 7</u>						<u>ACELERÓMETRO 8</u>					
	FASE 1			FASE 2			FASE 1			FASE 2		
	frec1	frec2	frec3	frec1	frec2	frec3	frec1	frec2	frec3	frec1	frec2	frec3
<u>A1X</u>	0.861	0.851	0.861	0.599	0.614	0.601	0.752	0.723	0.751	0.590	0.583	0.453
<u>A1Y</u>	0.866	0.796	0.779	0.618	0.617	0.517	0.805	0.742	0.802	0.591	0.596	0.585
<u>A1Z</u>	0.722	0.859	0.723	0.591	0.480	0.466	0.797	0.873	0.806	0.436	0.575	0.518
<u>A2X</u>	0.437	0.487	0.521	0.000	0.000	0.000	0.191	0.212	0.190	0.000	0.000	0.000
<u>A2Y</u>	0.528	0.555	0.353	0.000	0.000	0.000	0.211	0.221	0.231	0.000	0.000	0.000
<u>A2Z</u>	0.536	0.715	0.612	0.000	0.000	0.000	0.460	0.359	0.544	0.000	0.000	0.000
<u>A3X</u>	0.682	0.632	0.617	0.572	0.594	0.591	0.701	0.612	0.700	0.597	0.584	0.457
<u>A3Y</u>	0.573	0.376	0.561	0.674	0.673	0.520	0.716	0.721	0.713	0.678	0.686	0.679
<u>A3Z</u>	0.752	0.823	0.670	0.632	0.606	0.704	0.747	0.689	0.847	0.594	0.674	0.670
<u>A4X</u>	0.626	0.732	0.622	0.536	0.560	0.568	0.576	0.740	0.577	0.461	0.393	0.353
<u>A4Y</u>	0.719	0.681	0.675	0.617	0.616	0.499	0.814	0.798	0.810	0.600	0.609	0.597
<u>A4Z</u>	0.821	0.886	0.734	0.590	0.540	0.434	0.835	0.774	0.845	0.570	0.582	0.555
<u>A5X</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A5Y</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A5Z</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A6X</u>	0.662	0.701	0.660	0.444	0.470	0.470	0.857	0.781	0.855	0.370	0.319	0.352
<u>A6Y</u>	0.582	0.320	0.575	0.568	0.568	0.335	0.855	0.743	0.853	0.425	0.424	0.412
<u>A6Z</u>	0.711	0.693	0.606	0.427	0.551	0.443	0.677	0.809	0.749	0.232	0.307	0.397

Se observa que el grado de correlación disminuye notablemente de la Fase 1 a la Fase 2. El cambio de posición de los sensores es el motivo de esta diferencia. Se recuerda que los puntos de medición de la Fase 2 están más próximos a los acelerómetros fijos mientras que la Fase 1 es la más cercana a los extremos libres de la estructura. Debido a esto, el grado de correlación es mayor a medida que nos acercamos a ese extremo libre del puente.

Por lo expuesto anteriormente no se muestran datos sobre las correlaciones en la Fase 3 de medición, ya que incluso inferiores a los obtenidos en segunda fase y no son relevantes.

El nivel de confianza se ha fijado en un 75%, en la *Tabla 5.3.* aparecen resaltados los valores superiores a este límite. Estos puntos serán los utilizados para entrenar y validar la herramienta.

Tabla 5.3. Correlaciones Optimas

	<u>ACELERÓMETRO 7</u>						<u>ACELERÓMETRO 8</u>					
	<i>FASE 1</i>			<i>FASE 2</i>			<i>FASE 1</i>			<i>FASE 2</i>		
	frec 1	frec 2	frec 3	frec 1	frec 2	frec 3	frec 1	frec 2	frec 3	frec 1	frec 2	frec 3
<u>A1X</u>	0.861	0.851	0.861	0.599	0.614	0.601	0.752	0.723	0.751	0.590	0.583	0.453
<u>A1Y</u>	0.866	0.796	0.779	0.618	0.617	0.517	0.805	0.742	0.802	0.591	0.596	0.585
<u>A1Z</u>	0.722	0.859	0.723	0.591	0.480	0.466	0.797	0.873	0.806	0.436	0.575	0.518
<u>A2X</u>	0.437	0.487	0.521	0.000	0.000	0.000	0.191	0.212	0.190	0.000	0.000	0.000
<u>A2Y</u>	0.528	0.555	0.353	0.000	0.000	0.000	0.211	0.221	0.231	0.000	0.000	0.000
<u>A2Z</u>	0.536	0.715	0.612	0.000	0.000	0.000	0.460	0.359	0.544	0.000	0.000	0.000
<u>A3X</u>	0.682	0.632	0.617	0.572	0.594	0.591	0.701	0.612	0.700	0.597	0.584	0.457
<u>A3Y</u>	0.573	0.376	0.561	0.674	0.673	0.520	0.716	0.721	0.713	0.678	0.686	0.679
<u>A3Z</u>	0.752	0.823	0.670	0.632	0.606	0.704	0.747	0.689	0.847	0.594	0.674	0.670
<u>A4X</u>	0.626	0.732	0.622	0.536	0.560	0.568	0.576	0.740	0.577	0.461	0.393	0.353
<u>A4Y</u>	0.719	0.681	0.675	0.617	0.616	0.499	0.814	0.798	0.810	0.600	0.609	0.597
<u>A4Z</u>	0.821	0.886	0.734	0.590	0.540	0.434	0.835	0.774	0.845	0.570	0.582	0.555
<u>A5X</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A5Y</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A5Z</u>	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
<u>A6X</u>	0.662	0.701	0.660	0.444	0.470	0.470	0.857	0.781	0.855	0.370	0.319	0.352
<u>A6Y</u>	0.582	0.320	0.575	0.568	0.568	0.335	0.855	0.743	0.853	0.425	0.424	0.412
<u>A6Z</u>	0.711	0.693	0.606	0.427	0.551	0.443	0.677	0.809	0.749	0.232	0.307	0.397

Frecuencias y modos de vibración

En todas las etapas de preproceso y estudio estadístico se ha trabajado con las 3 primeras frecuencias de la señal. Cuantas más frecuencias se utilicen los resultados finales serán más próximos a la solución exacta y más complejos de tratar.

En campo de mantenimiento de estructuras se necesita por lo general menos precisión en cuanto a la solución numérica se refiere. Pero se debe de tener en cuenta otro factor, el modo de excitación de la estructura. Dependiendo del tipo de cargas que producen la excitación, la respuesta del puente vendrá asociada a modos de vibración diferentes. Tal y como se ha explicado en el apartado 3.5. *ANÁLISIS MODAL OPERACIONAL Y EXPERIMENTAL*, para el caso de

estudio, las cargas que producen nuestra señal son cargas asociadas al régimen de trabajo nominal del puente (paso de trenes) y, por ello el modo de excitación de dicha estructura será casi exclusivo del primer modo de vibración (frecuencia principal). Debido a esto el análisis llevado a cabo para este proyecto se basa en el análisis modal experimental.

En definitiva, utilizando la primera frecuencia obtenida en el preproceso, no solo tendremos la precisión requerida, sino que está justificado debido al modo de excitación de la estructura.

En la *Tabla 5.4.* Resumen de correlaciones y la *Figura 5.11.* Inputs-Outputs de los Modelos A7 y A8 se muestran los acelerómetros que se utilizarán para entrenar nuestra herramienta.

Tabla 5.4. Resumen de correlaciones

	A7	A8		A7	A8
<u>A1X</u>	0.861	0.752	<u>A3X</u>		
<u>A1Y</u>	0.866	0.805	<u>A3Y</u>		
<u>A1Z</u>		0.797	<u>A3Z</u>	0.752	
<u>A4X</u>			<u>A6X</u>		0.857
<u>A4Y</u>		0.814	<u>A6Y</u>		0.855
<u>A4Z</u>	0.821	0.835	<u>A6Z</u>		




Figura 5.11. Inputs-Outputs de los Modelos A7 y A8

5.7.3 Generación de datos adicionales sintéticos mediante Montecarlo (benchmarking sintético)

Debido a que únicamente se dispone de 20 muestras de calidad para la elaboración del modelo estadístico de *SHM*, se ha llevado a cabo una simulación de datos adicionales mediante técnicas de análisis de Montecarlo (explicadas en el apartado 4.5. *VALIDACIÓN DE HERRAMIENTA*).

De esta forma se consiguen un total de 100 muestras para cada acelerómetro que se dividirán en dos bloques:

- Fase de entrenamiento: Recogerá el 70% de las muestras obtenidas y servirá para entrenar nuestro sistema.
- Fase de validación: Abarca el 30% restante de muestras y se utilizará para comprobar como de fiable es el modelo obtenido en la fase anterior.

5.7.4 Regresión Múltiple (Multioutput Regressor): Gradient Boosting

En el apartado 3.6. *MACHINE LEARNING AND DATA ANALYTICS* se ha explicado con detalle los tipos de herramientas existentes para realizar los modelos de predicción basados en aprendizaje automático. También se han expuesto los motivos por los que se utilizará un sistema de Regresión Múltiple, concretamente de dos salidas.

El objetivo, cabe recordar, es lograr obtener una herramienta que sea capaz de predecir la respuesta en cualquier punto del puente a partir de los acelerómetros fijos colocados. Nuestra herramienta, por tanto, entrenará de forma independiente a cada uno de ellos con los acelerómetros que mejor relación tienen con cada uno.

La herramienta *Colaboratory*, mediante lenguaje *Python*, permite trabajar con casi cualquier método de regresión aplicado a sistemas multirrespuesta.

En este trabajo se utilizará el método de regresión *Gradient Boosting* explicado en el apartado 3.4.3. *Gradient Boosting*. El código completo para el diseño de esta herramienta aparece en el *ANEXO I: SCRIPTS UTILIZADOS*

5.7.5 Fase 1: Entrenamiento

Para la construcción del sistema de *Machine Learning* se utilizarán un total de 70 muestras (las 20 originales más 50 adicionales obtenidas de forma sintética). En la *Tabla 5.5*. Valores de entrenamiento de la herramienta se recogen los valores de entrenamiento tanto para el acelerómetro 7 como para el 8.

Tabla 5.5. Valores de entrenamiento de la herramienta

<u>A1X</u>	<u>A1Y</u>	<u>A3Z</u>	<u>A4Z</u>	<u>A7X</u>	<u>A7Y</u>	<u>A7Z</u>	<u>A6X</u>	<u>A4Y</u>	<u>A6Y</u>	<u>A1Z</u>	<u>A8X</u>	<u>A8Y</u>	<u>A8Z</u>
6.55	6.47	6.33	6.18	6.47	2.39	5.89	8.99	6.42	2.39	5.94	2.39	6.38	5.79
3.10	6.50	5.76	5.76	6.40	2.39	4.93	9.06	6.38	2.39	5.76	2.39	6.35	7.65
6.47	6.42	14.12	14.12	5.15	2.39	11.53	8.96	6.35	2.39	14.12	2.39	6.42	11.53
4.49	6.45	6.16	6.33	6.45	2.39	5.96	6.52	6.45	2.39	6.33	2.39	6.38	7.42
5.76	6.25	5.72	6.35	5.81	2.39	6.13	6.45	5.50	2.37	6.30	2.39	6.35	7.87
6.50	6.33	5.76	5.72	6.45	2.42	16.78	9.01	6.45	2.42	5.37	2.42	6.35	5.91
4.47	6.45	5.84	6.25	6.16	2.39	4.91	5.74	6.16	2.39	6.16	2.39	6.42	5.89
6.47	5.69	4.32	5.76	6.50	2.39	5.74	6.47	6.35	2.39	14.22	2.39	6.38	5.47
6.30	6.38	5.83	5.79	6.47	4.93	6.35	9.02	6.33	2.42	5.42	2.43	6.42	5.65
6.45	6.35	6.18	5.28	6.47	2.42	6.11	5.28	6.38	2.42	7.74	2.42	6.42	5.62
4.49	6.38	5.32	6.01	6.25	2.39	5.37	6.28	5.42	2.39	5.45	2.39	6.40	5.11
4.37	6.42	5.89	5.18	6.42	2.39	5.84	2.39	6.40	2.39	13.17	2.39	6.23	7.62
6.55	6.45	5.86	6.20	6.42	2.42	5.86	9.04	6.45	2.42	5.62	2.42	6.30	5.86
6.50	6.42	13.17	13.17	6.47	2.39	15.56	6.06	6.45	2.39	13.17	2.39	6.38	15.58
6.52	6.50	6.23	6.23	6.50	2.39	5.86	8.94	6.35	2.39	7.77	2.39	6.35	5.81
6.52	6.45	6.23	6.23	6.25	2.39	5.91	8.96	6.42	2.39	7.67	2.39	6.30	5.91
3.27	6.42	6.24	6.25	6.45	2.39	5.84	8.94	6.30	2.42	6.25	2.39	6.55	9.75
4.62	6.40	5.97	5.72	6.47	2.39	5.94	9.16	6.33	2.39	6.28	2.39	6.38	7.52
4.85	6.45	5.81	6.23	6.38	2.42	5.62	2.39	6.38	2.42	5.77	2.39	6.33	4.69
4.42	6.45	6.23	5.79	5.35	2.39	6.11	5.54	6.40	2.39	6.25	2.39	6.25	4.93
5.02	6.32	5.80	5.89	6.13	2.33	5.93	6.39	6.18	2.40	6.64	2.40	6.34	6.16
5.86	6.44	7.53	7.59	6.40	2.73	8.33	7.95	6.39	2.41	8.87	2.40	6.39	8.02
5.72	6.42	7.23	7.30	6.36	2.66	7.92	7.68	6.35	2.40	8.48	2.40	6.38	7.70
4.89	6.30	5.55	5.65	6.09	2.27	5.59	6.17	6.15	2.39	6.32	2.39	6.34	5.89
3.89	6.16	3.50	3.64	5.77	1.79	2.75	4.33	5.91	2.38	3.69	2.38	6.28	3.69
5.82	6.44	7.43	7.49	6.39	2.71	8.19	7.86	6.38	2.40	8.74	2.40	6.39	7.92
3.47	6.10	2.64	2.79	5.63	1.59	1.56	3.56	5.81	2.38	2.58	2.38	6.25	2.77
5.84	6.44	7.47	7.53	6.39	2.72	8.25	7.90	6.38	2.40	8.79	2.40	6.39	7.96
7.28	6.65	10.41	10.42	6.86	3.40	12.32	10.54	6.73	2.42	12.57	2.42	6.47	11.13
5.10	6.33	5.96	6.05	6.16	2.37	6.16	6.55	6.20	2.40	6.86	2.40	6.35	6.34
5.82	6.44	7.45	7.51	6.39	2.71	8.22	7.88	6.38	2.40	8.76	2.40	6.39	7.94
6.76	6.57	9.36	9.39	6.69	3.16	10.87	9.60	6.61	2.42	11.23	2.41	6.44	10.00
4.88	6.30	5.53	5.63	6.09	2.26	5.56	6.15	6.15	2.39	6.30	2.39	6.34	5.87
5.82	6.44	7.43	7.50	6.39	2.71	8.20	7.86	6.38	2.40	8.74	2.40	6.39	7.92
3.09	6.04	1.86	2.02	5.51	1.41	0.48	2.86	5.71	2.37	1.58	2.38	6.23	1.93
7.54	6.69	10.95	10.95	6.94	3.53	13.07	11.03	6.79	2.42	13.27	2.42	6.49	11.71
5.91	6.45	7.63	7.69	6.42	2.75	8.47	8.04	6.40	2.41	9.00	2.40	6.39	8.13
5.93	6.45	7.66	7.72	6.42	2.76	8.51	8.07	6.40	2.41	9.04	2.40	6.40	8.17
5.26	6.36	6.29	6.38	6.21	2.44	6.62	6.84	6.24	2.40	7.28	2.40	6.36	6.70
3.56	6.11	2.82	2.97	5.66	1.63	1.81	3.72	5.83	2.38	2.82	2.38	6.26	2.96
7.75	6.72	11.38	11.37	7.01	3.63	13.67	11.41	6.85	2.43	13.82	2.42	6.50	12.17
4.44	6.24	4.62	4.73	5.95	2.05	4.30	5.33	6.04	2.39	5.13	2.39	6.31	4.89
4.49	6.24	4.72	4.83	5.96	2.08	4.44	5.42	6.05	2.39	5.25	2.39	6.31	5.00
5.58	6.40	6.95	7.02	6.31	2.60	7.53	7.43	6.32	2.40	8.13	2.40	6.38	7.40
6.13	6.48	8.06	8.11	6.49	2.85	9.07	8.43	6.45	2.41	9.55	2.41	6.41	8.60
6.74	6.57	9.31	9.34	6.68	3.14	10.80	9.55	6.60	2.41	11.16	2.41	6.44	9.94
7.43	6.67	10.72	10.73	6.91	3.47	12.76	10.82	6.77	2.42	12.97	2.42	6.48	11.46
4.97	6.31	5.70	5.79	6.12	2.30	5.79	6.31	6.17	2.40	6.51	2.39	6.34	6.06
6.19	6.49	8.18	8.23	6.51	2.88	9.24	8.54	6.47	2.41	9.71	2.41	6.41	8.73
6.07	6.47	7.95	8.00	6.47	2.83	8.91	8.33	6.44	2.41	9.41	2.40	6.40	8.48
5.91	6.45	7.61	7.67	6.42	2.75	8.45	8.03	6.40	2.41	8.97	2.40	6.39	8.12
4.37	6.23	4.49	4.60	5.93	2.02	4.12	5.22	6.03	2.39	4.96	2.39	6.31	4.75
5.67	6.42	7.12	7.19	6.34	2.64	7.77	7.59	6.34	2.40	8.35	2.40	6.38	7.59
5.38	6.37	6.53	6.62	6.25	2.50	6.96	7.06	6.27	2.40	7.59	2.40	6.36	6.96
3.23	6.06	2.16	2.32	5.56	1.48	0.89	3.12	5.75	2.38	1.96	2.38	6.24	2.25
5.94	6.45	7.69	7.75	6.43	2.77	8.55	8.10	6.41	2.41	9.07	2.40	6.40	8.20
5.05	6.33	5.86	5.95	6.14	2.34	6.02	6.45	6.19	2.40	6.73	2.40	6.35	6.23
6.77	6.58	9.38	9.41	6.70	3.16	10.90	9.62	6.61	2.42	11.25	2.41	6.44	10.02

<u>A1X</u>	<u>A1Y</u>	<u>A3Z</u>	<u>A4Z</u>	<u>A7X</u>	<u>A7Y</u>	<u>A7Z</u>	<u>A6X</u>	<u>A4Y</u>	<u>A6Y</u>	<u>A1Z</u>	<u>A8X</u>	<u>A8Y</u>	<u>A8Z</u>
5.30	6.36	6.37	6.46	6.22	2.46	6.73	6.91	6.25	2.40	7.39	2.40	6.36	6.78
2.66	5.98	0.99	1.17	5.38	1.21	-0.72	2.08	5.61	2.37	0.47	2.37	6.21	0.99
6.89	6.59	9.63	9.65	6.73	3.22	11.24	9.84	6.64	2.42	11.56	2.41	6.45	10.28
5.73	6.42	7.24	7.31	6.36	2.66	7.94	7.70	6.35	2.40	8.50	2.40	6.38	7.72
8.65	6.85	13.20	13.16	7.30	4.05	16.19	13.05	7.06	2.44	16.16	2.43	6.55	14.13
5.73	6.42	7.25	7.32	6.36	2.67	7.94	7.70	6.35	2.40	8.51	2.40	6.38	7.73
4.87	6.30	5.50	5.60	6.08	2.26	5.52	6.13	6.15	2.39	6.26	2.39	6.33	5.84
5.85	6.44	7.50	7.56	6.40	2.72	8.29	7.93	6.38	2.41	8.83	2.40	6.39	7.99
5.05	6.33	5.87	5.96	6.14	2.34	6.03	6.46	6.19	2.40	6.73	2.40	6.35	6.24
5.93	6.45	7.66	7.72	6.42	2.76	8.51	8.07	6.40	2.41	9.03	2.40	6.40	8.17
5.56	6.40	6.91	6.98	6.31	2.59	7.48	7.40	6.31	2.40	8.07	2.40	6.37	7.36
4.35	6.22	4.43	4.55	5.92	2.01	4.04	5.17	6.02	2.39	4.89	2.39	6.30	4.70

Con los datos mostrados se realiza el entrenamiento del modelo. Para ello se alimentará el sistema con los datos que trabajará el modelo, es decir, los valores de los acelerómetros fijos y los acelerómetros variables.

5.7.6 Fase 2: Validación

Una vez que termina el entrenamiento, se procede a realizar la validación del modelo creado.

Se utilizarán 30 muestras generadas de forma aleatoria que están registradas en la *Tabla 5.6*.

Datos de validación de la herramienta

Tabla 5.6. Datos de validación de la herramienta

<u>A1X</u>	<u>A1Y</u>	<u>A3Z</u>	<u>A4Z</u>	<u>A7X</u>	<u>A7Y</u>	<u>A7Z</u>	<u>A6X</u>	<u>A4Y</u>	<u>A6Y</u>	<u>A1Z</u>	<u>A8X</u>	<u>A8Y</u>	<u>A8Z</u>
4.61	6.26	4.97	5.08	6.00	2.14	4.79	5.65	6.08	2.39	5.58	2.39	6.32	5.28
6.70	6.56	9.24	9.27	6.67	3.13	10.70	9.49	6.59	2.41	11.07	2.41	6.44	9.87
9.61	6.98	15.16	15.08	7.60	4.51	18.90	14.81	7.29	2.45	18.68	2.44	6.61	16.24
4.78	6.29	5.31	5.42	6.06	2.22	5.26	5.96	6.12	2.39	6.02	2.39	6.33	5.64
6.27	6.50	8.36	8.41	6.54	2.92	9.49	8.70	6.49	2.41	9.94	2.41	6.42	8.92
5.84	6.44	7.48	7.55	6.40	2.72	8.27	7.91	6.38	2.40	8.81	2.40	6.39	7.98
5.36	6.37	6.50	6.58	6.24	2.49	6.90	7.03	6.26	2.40	7.54	2.40	6.36	6.92
6.40	6.52	8.62	8.67	6.58	2.99	9.85	8.94	6.52	2.41	10.28	2.41	6.42	9.20
6.92	6.60	9.67	9.70	6.74	3.23	11.30	9.88	6.64	2.42	11.62	2.41	6.45	10.33
4.34	6.22	4.42	4.54	5.91	2.01	4.02	5.16	6.02	2.39	4.87	2.39	6.30	4.68
6.28	6.50	8.37	8.42	6.54	2.93	9.50	8.71	6.49	2.41	9.95	2.41	6.42	8.93
8.43	6.81	12.76	12.73	7.23	3.95	15.58	12.65	7.01	2.43	15.59	2.43	6.54	13.65
8.21	6.78	12.31	12.29	7.16	3.84	14.95	12.25	6.96	2.43	15.01	2.42	6.53	13.17
6.31	6.51	8.43	8.48	6.55	2.94	9.58	8.76	6.49	2.41	10.03	2.41	6.42	9.00
8.46	6.82	12.82	12.79	7.24	3.96	15.67	12.71	7.02	2.43	15.68	2.43	6.54	13.73
3.31	6.07	2.31	2.47	5.58	1.52	1.11	3.26	5.77	2.38	2.17	2.38	6.24	2.42
3.38	6.08	2.45	2.61	5.60	1.55	1.30	3.39	5.78	2.38	2.34	2.38	6.25	2.56
6.65	6.56	9.12	9.16	6.65	3.10	10.54	9.38	6.58	2.41	10.92	2.41	6.44	9.74
5.53	6.40	6.85	6.92	6.30	2.57	7.39	7.34	6.31	2.40	7.99	2.40	6.37	7.29
4.50	6.25	4.75	4.86	5.97	2.08	4.48	5.45	6.06	2.39	5.30	2.39	6.31	5.04
2.46	5.95	0.58	0.77	5.31	1.11	-1.29	1.71	5.56	2.37	-0.06	2.37	6.20	0.55
4.77	6.29	5.30	5.40	6.05	2.21	5.25	5.95	6.12	2.39	6.01	2.39	6.33	5.63
4.52	6.25	4.78	4.90	5.97	2.09	4.53	5.49	6.06	2.39	5.34	2.39	6.31	5.07
5.15	6.34	6.07	6.16	6.17	2.39	6.32	6.64	6.21	2.40	7.00	2.40	6.35	6.46
5.45	6.38	6.68	6.76	6.27	2.53	7.16	7.19	6.29	2.40	7.78	2.40	6.37	7.11
7.30	6.65	10.46	10.47	6.87	3.41	12.40	10.59	6.74	2.42	12.64	2.42	6.47	11.18
5.52	6.39	6.83	6.91	6.29	2.57	7.36	7.33	6.30	2.40	7.97	2.40	6.37	7.28
6.04	6.47	7.88	7.93	6.46	2.81	8.82	8.27	6.43	2.41	9.32	2.40	6.40	8.40

5.45	6.38	6.68	6.76	6.27	2.53	7.16	7.19	6.29	2.40	7.78	2.40	6.37	7.12
2.97	6.02	1.62	1.79	5.47	1.36	0.14	2.64	5.68	2.37	1.27	2.38	6.23	1.67

Una vez que se dispone de la muestra de validación, el procedimiento a seguir es similar al realizado con los datos de la muestra original. Los valores de frecuencia resultantes en los acelerómetros fijos (valores de predicción) se calcularán mediante la herramienta ya entrenada de Machine Learning. Estos valores obtenidos se compararán con los valores calculados mediante simulación, es decir, el modelo de referencia.

5.7.7 Comparación de resultados

Para comparar los resultados y comprobar el nivel de precisión de la herramienta a implementar se mostrará de forma gráfica el valor obtenido en la predicción de dicha herramienta y el valor real calculado anteriormente. Se ha establecido un nivel de confianza del 5%.

En la *Figura 5.12*. Comparación de resultados del Acelerómetro 7X a *Figura 5.17* muestran los resultados de los acelerómetros 7 y 8:




Figura 5.12. Comparación de resultados del Acelerómetro 7X




Figura 5.13. Comparación de resultados del Acelerómetro 7Y




Figura 5.14. Comparación de resultados del Acelerómetro 7Z

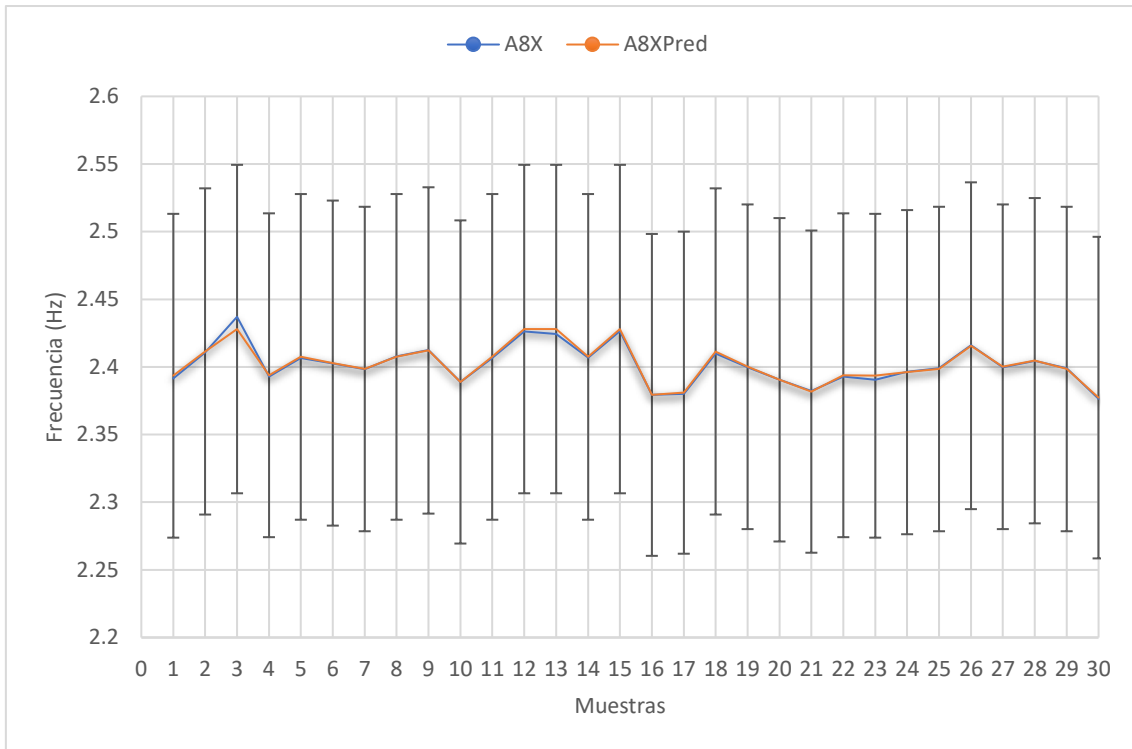


Figura 5.15. Comparación de resultados del Acelerómetro 8X

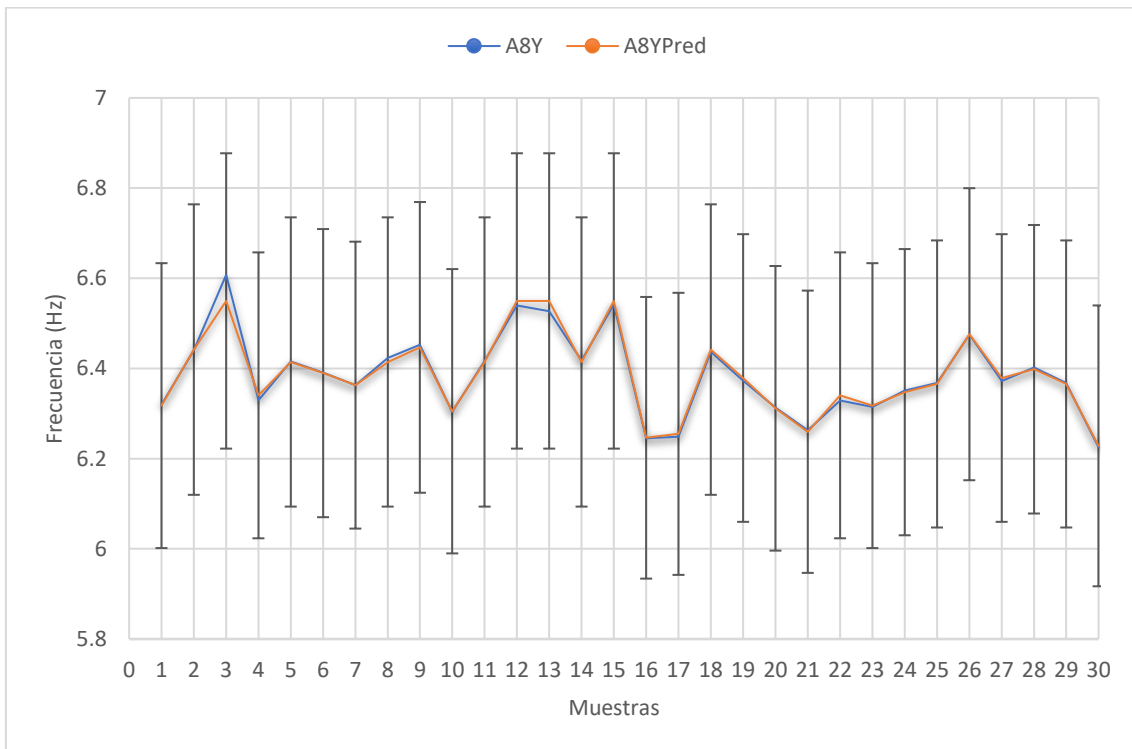


Figura 5.16. Comparación de resultados del Acelerómetro 8Y




Figura 5.17. Comparación de resultados del Acelerómetro 8Z

Se puede observar que los modelos de referencia y los de validación presentan comportamientos similares, si bien existen diferencias debido al tamaño de la muestra y a que el muestreo aleatorio no se ajusta de forma perfecta al comportamiento real de la estructura, si bien se adapta de manera considerable.

5.8 GENERACIÓN DE ESTADOS DE ALARMA

Una vez validada la herramienta con los datos reales y los datos sintéticos es necesario generar una serie de datos nuevos. Este nuevo conjunto de datos será utilizado para entrenar la herramienta fuera de los límites establecidos (por los datos reales de la estructura). Este entrenamiento adicional, con datos ficticios de alarma es necesario por los siguientes motivos.

- Número de datos reales de la estructura relativamente bajo: como ya se ha explicado, este tipo de herramienta será tanto más precisa cuanto más información disponga. Como los datos reales de la estructura son escasos, más escasos aún serán aquellos valores “anormales” que puedan activar el estado de alarma.
- En relación con el punto anterior, los datos recogidos corresponden al funcionamiento normal de la estructura, por lo que a priori no se deberían disponer de datos de daño o alarma en la estructura.
- Debido al método de *Gradient Boosting* utilizado siempre será necesario entrenar la herramienta con una serie de valores iniciales. La consecuencia de no proveer de dichos

valores es la siguiente: Cuando la herramienta reciba un dato de alarma (existe gran variación con los datos normales) no dispondrá de registros o nodos creados en ese rango de valores como para dar una respuesta eficiente. De hecho, lo más probable es que al recibir los primeros estados de alarma real, la herramienta devuelva valores corregidos hacia el estado de NO DAÑO.

Esto se evita con el entrenamiento adicional que se ha realizado. Generando estos datos, la herramienta ya dispone de suficiente información inicial como para poder diferenciar entre el estado de alarma y funcionamiento normal de la estructura. A medida que reciba más datos de alarma el error de dicha predicción se verá reducido (aunque siempre será mucho más preciso que sin realizar el entrenamiento adicional).

Para generar los datos se han establecido una serie de límites de control:

- Verde: Límite establecido por la desviación típica de cada componente de los acelerómetros A7 y A8.
- Amarillo: Límite establecido por dos desviaciones típicas de cada componente de los acelerómetros A7 y A8.
- Rojo: Límite establecido por tres desviaciones típicas de cada componente de los acelerómetros A7 y A8.

Con estos límites presentes se han generado los datos para entrenar la herramienta siguiendo el comportamiento real de la estructura (misma media obtenida en cada componente) pero con tres desviaciones típicas. De esta forma se obtendrán datos más extremos, lo que se necesita para generar estado de alarma en la estructura.

Mediante está generando estamos introduciendo cierto “ruido” a los datos iniciales, pero esta pérdida de precisión es temporal debido a la mejora continua de la herramienta. Nos sirve para calibrar la respuesta inicial al estado de alarma y solo es cuestión de tiempo de que mejore la robustez a medida que reciba datos.

5.8.1 Resultados

Los resultados obtenidos al entrenar la herramienta con los datos de alarma se muestran en la Figura 5.18 a Figura 5.23.




Figura 5.18. Alarma en A7X.

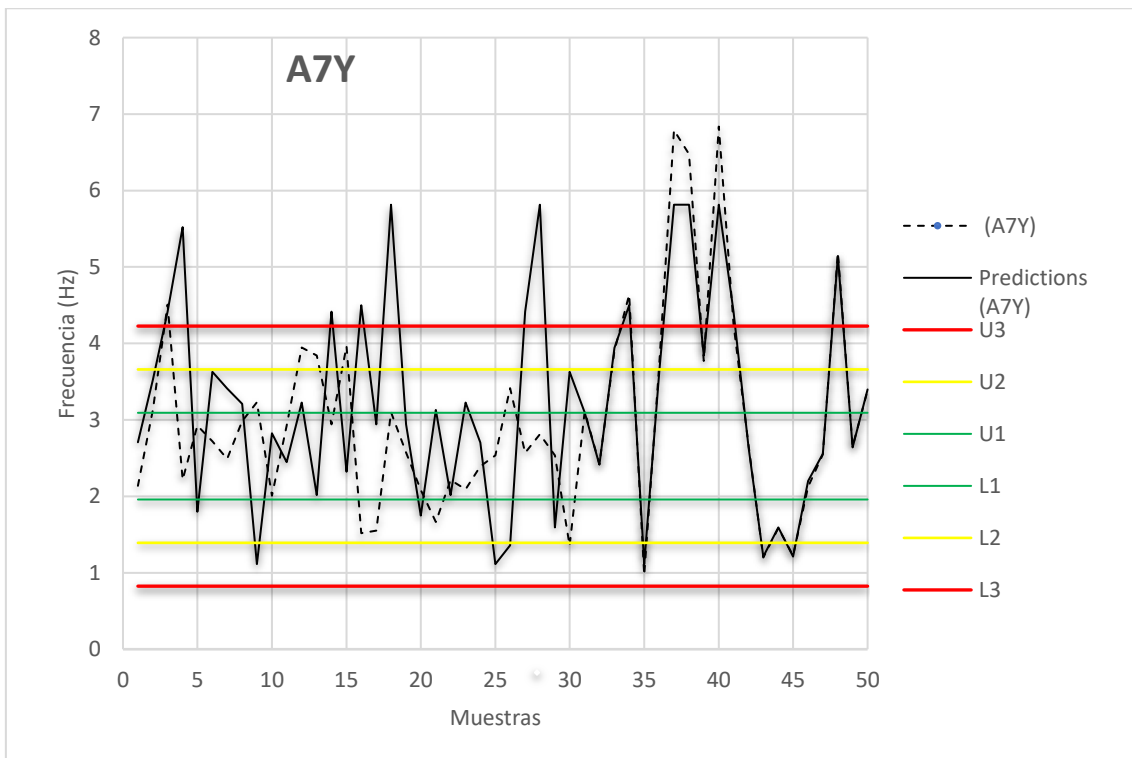


Figura 5.19. Alarma en A7Y.




Figura 5.20. Alarma en A7Z.

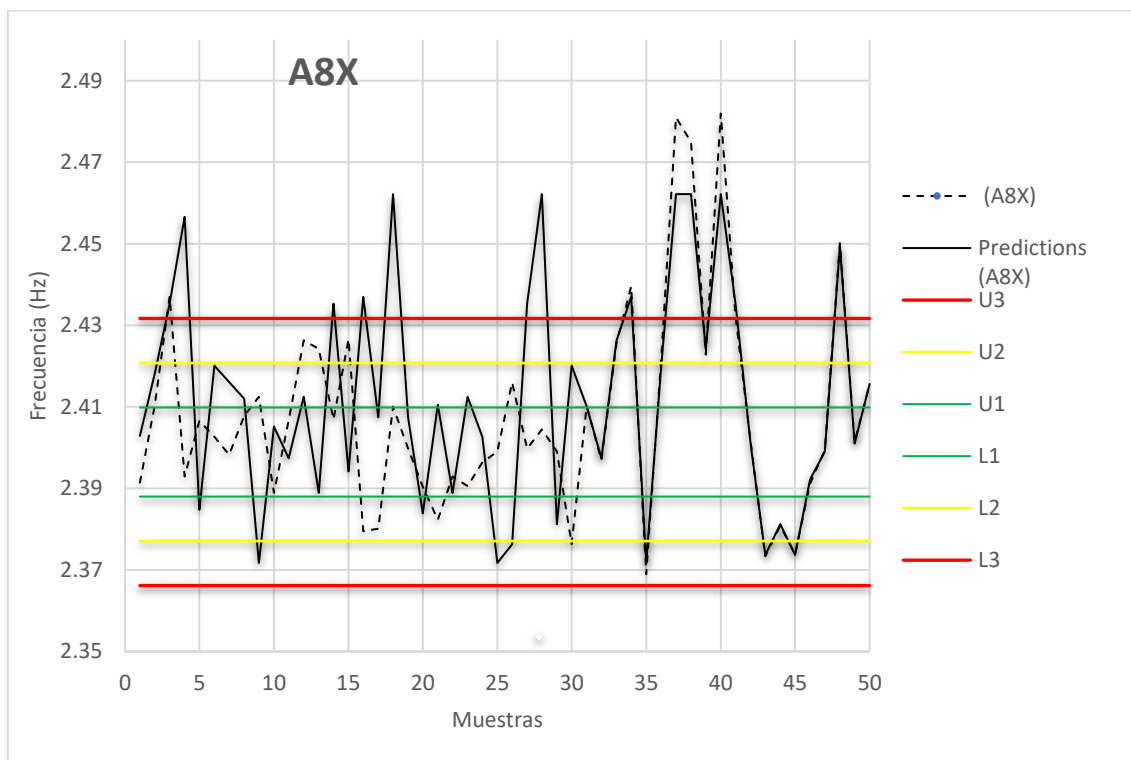


Figura 5.21. Alarma en A8X.




Figura 5.22. Alarma en A8Y




Figura 5.23. Alarma en A8Z

6 CONCLUSIONES

Se ha demostrado que los sistemas de monitorización estructural (*SHM*) necesitan una absoluta integración de estos en la estructura a analizar, pasando a formar parte de ella, así como una constante aportación de información de calidad sobre las condiciones de funcionamiento reales en las que opera.

El problema de la instrumentación y la adquisición de datos se ha superado en las últimas décadas gracias a los grandes avances tecnológicos, convirtiendo la *SHM* en una tecnología madura. Sin embargo, en este contexto, el reto fundamental reside en la capacidad de controlar los propios Sistemas Monitorización Estructural para transformar en conocimiento los datos adquiridos, creando estructuras inteligentes y la propia valorización de la tecnología como una inversión a largo plazo.

En este capítulo se presentan algunas de las conclusiones derivadas de la realización del proyecto y se plantean posibles líneas de investigación futuras que complementen y amplíen los conocimientos aportados por este trabajo.

6.1 Conclusiones sobre la instrumentación

La necesidad de aportar información precisa y fiable sobre la situación de los sistemas estructurales ha promovido la transición de las técnicas de instrumentación basadas en inspecciones visuales y otras valoraciones de carácter subjetivo, hacia los sistemas complejos de Monitorización Estructural. Esto ha sido posible gracias a la evolución de las tecnologías, que actualmente permiten adquirir grandes volúmenes de datos de calidad en tiempos reducidos, convirtiendo a las estructuras en una fuente inagotable de conocimiento.

Este concepto de *BIG DATA* en el ámbito de la instrumentación elimina la idea del dato como algo estático cuyo sentido y utilidad desaparece tras cumplir el objetivo funcional para el que fue adquirido, y plantea un nuevo enfoque en el que los datos se empleen de forma continuada, reutilizándose de forma inteligente como fuente de información constante y actualizada.

Cabe destacar también el carácter “reversible” de la información proporcionada por los sistemas de instrumentación de las estructuras, no solo como material de interés para la gestión de las propias redes, sino como fuente de conocimiento para otros ámbitos. Por ejemplo, la adquisición de datos de aceleraciones proporciona información de tráfico que puede resultar interesante desde el punto de vista económico, medioambiental y social. Es decir, que la información procedente de la instrumentación debe traspasar el nivel de red para responder a otras preguntas de carácter externo, convirtiendo a las estructuras no solo en puentes

materiales sino en puentes digitales de comunicación para que en el mundo actual nada esté aislado.

6.2 Conclusiones sobre las metodologías basadas en datos

En este trabajo se abordó el problema de la detección de daños estructurales desde la perspectiva de los modelos basados en datos dinámicos, que implican un fuerte componente estadístico en contraposición a las metodologías comúnmente utilizadas basada en la creación de modelos físicos computacionales mediante técnicas de elementos finitos.

Las principales ventajas de esta metodología residen en su versatilidad y su flexibilidad para adaptarse a cualquier tipo de sistema o estructura, independientemente del grado de complejidad.

6.3 Conclusiones sobre Machine Learning y su aplicación en el mantenimiento predictivo

Las técnicas de procesamiento de datos para obtener información relativa al estado estructural, como el *Gradient Boosting*, permiten simplificar mucho los datos conservando la información sensible al daño. El *Gradient Boosting* es una técnica de aprendizaje automático utilizado para el análisis de la regresión y para problemas de clasificación estadística, el cual produce un modelo predictivo en forma de un conjunto de modelos de predicción débiles, típicamente árboles de decisión.

El *Gradient Boosting* pertenece a las técnicas de Aprendizaje automático o aprendizaje de máquinas (*Machine Learning*) y, como todas las técnicas pertenecientes a la inteligencia artificial se dedica a desarrollar algoritmos que permitan a un programa aprender sobre la experiencia. En este caso concreto se ha trabajado con *Gradient Boosting* por su adecuación

Se sirve de experiencias y evidencias en forma de datos, con los que comprender por sí mismo patrones o comportamientos. De este modo, puede elaborar predicciones de escenarios o iniciar operaciones que son la solución para una tarea específica.

6.4 Conclusiones sobre la herramienta de detección de daños

En cuanto a la evaluación proporcionada por la herramienta, la representación temporal de los nuevos indicadores procedentes del estado desconocido de la estructura facilita la detección de tendencias en su comportamiento global y valorar la evolución del estado en el que se

encuentre. Por su parte, la comparación del modelo estadístico de los indicadores registrados permite comparar los resultados con el modelo de referencia representativo del estado no dañado e inferir la posible presencia de algún daño o malfuncionamiento.

La configuración de la herramienta está orientada para su utilización en revisiones diarias como instrumento complementario a las inspecciones visuales y otros métodos de evaluación subjetiva, aportando un enfoque objetivo, preciso y cuantitativo que permita definir adecuadamente la situación estructural.

ANEXO I: SCRIPTS UTILIZADOS

A continuación, se presenta el código empleado en cada una de las etapas descritas en la memoria. Esto comprende desde el preproceso de los datos iniciales hasta la fase de evaluación y validación de la herramienta utilizada.

I. PREPROCESO DE DATOS Y CÁLCULO DE FRECUENCIAS

```
%function analisis_frecuencias_BOLUETA_v06
cd 'D:\UNICAN\TFM\Propio_2'
%rmdir RESULTADOS s;
mkdir ("RESULTADOS") %%%ESTA LINEA SOLO SI QUEREMOS REINICIAR LA
CARPETA
mkdir ("VFREC")
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%CARGAMOS DATOS DEL EXCEL%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Son los informes de estado de TODAS las medidas%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
infomedida=1;finalmedida=29;
matrizAcel=xlsread('D:\UNICAN\TFM\Propio_2\MAPA_ACEL_Válidos.xlsx','MEDICIONES COMPLETAS','F3:M197');%195X8
vectorFase=xlsread('D:\UNICAN\TFM\Propio_2\MAPA_ACEL_Válidos.xlsx','MEDICIONES COMPLETAS','O3:O197');%195X1
vectorTemp=xlsread('D:\UNICAN\TFM\Propio_2\MAPA_ACEL_Válidos.xlsx','MEDICIONES COMPLETAS','D3:D197');%195X1
vectorHum=xlsread('D:\UNICAN\TFM\Propio_2\MAPA_ACEL_Válidos.xlsx','MEDICIONES COMPLETAS','E3:E197');%195X1

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%EJECUTAMOS BUCLE PRINCIPAL%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
for infomedida= 1 : finalmedida
infomedida
cd 'D:\UNICAN\TFM\Propio_2\RESULTADOS'
mkdir ("TEMPORAL")
cd 'D:\UNICAN\TFM\Propio_2'
i=1;
m=60000;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%INFORMES DE ESTADO PARA CADA MEDIDA%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
p=matrizAcel(infomedida,:); %1X8
InformeAcel=[p(1) p(1) p(1) p(2) p(2) p(2) p(3) p(3) p(3) p(4) p(4)
p(4) p(5) p(5) p(5) p(6) p(6) p(6) p(7) p(7) p(7) p(8) p(8) p(8)];
%%InformeAcel(1 X 24): Informe de estado de todos los acely para esa
medida
InformeFase=vectorFase(infomedida);%Evalúa la fase actual (1 X 1)
InformeTemperatura=vectorTemp(infomedida);%Dato de temperatura (1 X 1)
InformeHumedad=vectorHum(infomedida);%Dato de Humedad (1 X 1)
```

```

VInformeTemperatura=InformeTemperatura*ones(24,1);%24X1 %Directo
OUTPUT
VInformeHumedad=InformeHumedad*ones(24,1);%24X1 %Directo OUTPUT

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%CONDICIONES INICIALES%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Influyen en el criterio de selección de los picos%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
distmin=2000;%Longitud del tramo seleccionado desde el pico
t=linspace(0,60000,60000)'; %Vector tiempo para asociar a la posición
del pico
filtrominimo=4000;%Mínima distancia entre picos próximos para
selección
npeaksmax=10;% Picos máximos por señal
matrizfrecuencias=zeros(length(InformeAcel),3);%OUTPUT sin filtrar
tramos
matrizfrecuenciasfiltered=zeros(length(InformeAcel),3);%OUTPUT con
filtrado

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%CARGAMOS DATOS DE CAMPO%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
if infomedida>99
cargacop=['D:\UNICAN\TFM\Propio_2\MEDICIONES\MEDIDA
',num2str(infomedida),'.MAT'];
cargaren=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\MEDIDA
',num2str(infomedida),'.MAT'];
copyfile(cargacop,'D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL');
movefile(cargaren,"D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.ma
t");
fid{i}=load('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.mat');
time=fid{1,1}.Channel_1_Data(1:m,1);
elseif infomedida>9
cargacop=['D:\UNICAN\TFM\Propio_2\MEDICIONES\MEDIDA
0',num2str(infomedida),'.MAT'];
cargaren=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\MEDIDA
0',num2str(infomedida),'.MAT'];
copyfile(cargacop,'D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL');
movefile(cargaren,"D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.ma
t");
fid{i}=load('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.mat');
time=fid{1,1}.Channel_1_Data(1:m,1);
else
cargacop=['D:\UNICAN\TFM\Propio_2\MEDICIONES\MEDIDA
00',num2str(infomedida),'.MAT'];
cargaren=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\MEDIDA
00',num2str(infomedida),'.MAT'];
copyfile(cargacop,'D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL');
movefile(cargaren,"D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.ma
t");
fid{i}=load('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\DATOS.mat');
time=fid{1,1}.Channel_1_Data(1:m,1);
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%FUNCION FILTRADERIVA%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
A1=filtraderiva(fid{1,1}.Channel_2_Data(1:m,1),time);
A2=filtraderiva(fid{1,1}.Channel_3_Data(1:m,1),time);
A3=filtraderiva(fid{1,1}.Channel_4_Data(1:m,1),time);
A4=filtraderiva(fid{1,1}.Channel_5_Data(1:m,1),time);
A5=filtraderiva(fid{1,1}.Channel_6_Data(1:m,1),time);
A6=filtraderiva(fid{1,1}.Channel_7_Data(1:m,1),time);
A7=filtraderiva(fid{1,1}.Channel_8_Data(1:m,1),time);
A8=filtraderiva(fid{1,1}.Channel_9_Data(1:m,1),time);
A9=filtraderiva(fid{1,1}.Channel_10_Data(1:m,1),time);
A10=filtraderiva(fid{1,1}.Channel_11_Data(1:m,1),time);

```

```

A11=filtraderiva(fid{1,1}.Channel_12_Data(1:m,1),time);
A12=filtraderiva(fid{1,1}.Channel_13_Data(1:m,1),time);
A13=filtraderiva(fid{1,1}.Channel_14_Data(1:m,1),time);
A14=filtraderiva(fid{1,1}.Channel_15_Data(1:m,1),time);
A15=filtraderiva(fid{1,1}.Channel_16_Data(1:m,1),time);
%A16=filtraderiva(fid{1,1}.Channel_17_Data(1:m,1),time);
A17=filtraderiva(fid{1,1}.Channel_18_Data(1:m,1),time);
A18=filtraderiva(fid{1,1}.Channel_19_Data(1:m,1),time);
A19=filtraderiva(fid{1,1}.Channel_20_Data(1:m,1),time);
A20=filtraderiva(fid{1,1}.Channel_21_Data(1:m,1),time);
A21=filtraderiva(fid{1,1}.Channel_22_Data(1:m,1),time);
A22=filtraderiva(fid{1,1}.Channel_23_Data(1:m,1),time);
A23=filtraderiva(fid{1,1}.Channel_24_Data(1:m,1),time);
A24=filtraderiva(fid{1,1}.Channel_25_Data(1:m,1),time);
A25=filtraderiva(fid{1,1}.Channel_26_Data(1:m,1),time);
%%%%MATRIZ A(60000 X 24): Contiene TODOS los Acel. (se reinicia cada
medida)
A=[A1 A2 A3 A4 A5 A6 A7 A8 A9 A10 A11 A12 A13 A14 A15 A17 A18 A19 A20
A21 A22 A23 A24 A25];

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%NOMBRES DE GRAFICAS%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%FASE 1%%%%%%%%

if InformeFase == 1
    Names=["A1X" "A1Y" "A1Z" "A2X" "A2Y" "A2Z" "A3X" "A3Y" "A3Z" "A4X"
"A4Y" "A4Z" "A5X" "A5Y" "A5Z" "A6X" "A6Y" "A6Z" "A7X" "A7Y" "A7Z"
"A8X" "A8Y" "A8Z"];
end

%%%%%%%%FASE 2%%%%%%%%

if InformeFase == 2
    Names=["A9X" "A9Y" "A9Z" "A10X" "A10Y" "A10Z" "A11X" "A11Y" "A11Z"
"A12X" "A12Y" "A12Z" "A13X" "A13Y" "A13Z" "A14X" "A14Y" "A14Z" "A7X"
"A7Y" "A7Z" "A8X" "A8Y" "A8Z"];
end

%%%%%%%%FASE 3%%%%%%%%

if InformeFase == 3
    Names=["A15X" "A15Y" "A15Z" "A16X" "A16Y" "A16Z" "A17X" "A17Y" "A17Z"
"A18X" "A18Y" "A18Z" "A19X" "A19Y" "A19Z" "A20X" "A20Y" "A20Z" "A7X"
"A7Y" "A7Z" "A8X" "A8Y" "A8Z"];
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%LOCALIZAMOS PICOS Y TRAMOS%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Afilter=[];tfilter=[];
k=1;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%BUCLE DE CAMBIO DE ACELEROMETRO%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
for k=1:length(InformeAcel)
    Atemp=[];ttemp=[];

    if InformeAcel(1,k)==1
        plot(t,A(:,k), 'b');
        xlabel('Time (s)')
        ylabel('Acceleration (m/s2)')
        titlename1=['Acceleration ',num2str(Names(k))];
        title(titlename1);
        %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%LOCALIZAMOS Y FILTRAMOS PICOS%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
        minvalue=0.2*max(A(:,k));minprom=0.1*max(A(:,k));

        [peaks,locs]=findpeaks(A(:,k),'minpeakdistance',distmin,'minpeakheight',minvalue,'Npeaks',10);
        npeaks=length(peaks);
        locsfilter=[];peaksfilter=[];
        for q=1:(npeaks-1)

```

```

        dist=locs(q+1)-locs(q);
        if dist>filtrominimo
            locsfilter=[locsfilter;locs(q)];
            peaksfilter=[peaksfilter;peaks(q)];
        end
    end
    q=npeaks;
    dist=60000-locs(q);
    if dist>filtrominimo
        locsfilter=[locsfilter;locs(q)];
        peaksfilter=[peaksfilter;peaks(q)];
    end
    npeaksfilter=length(locsfilter);
    if npeaksfilter>0
        for g=1:npeaksfilter
            Atemp=[Atemp;A(locsfilter(g):(locsfilter(g)+distmin-1),k)];
            ttemp=[ttemp;t(locsfilter(g):(locsfilter(g)+distmin-1))];
        end
        if npeaksfilter==npeaksmax
            Afilter=[Afilter Atemp];
            tfilter=[tfilter ttemp];
        else
            Atemp(distmin*npeaksmax,1)=0;
            ttemp(distmin*npeaksmax,1)=0;
            Afilter=[Afilter Atemp];
            tfilter=[tfilter ttemp];
        end
        %OJO: tfilter AHORA SERÁ MATRIZ.....t ERA VECTOR (común para
        todos)
        hold on
        plot(locs,peaks,'r+');
        plot(locsfilter,peaksfilter,'go');
        for c=1:npeaksfilter
            plot(tfilter((c*distmin-
distmin+1):distmin*c),k),Afilter((c*distmin-distmin+1):distmin*c),k),
            'g');
        end
        grid on
        grid minor
        xlabel('Time (s)')
        ylabel('Acceleration (m/s2)')
        titlename2=['Accel. Filtered ',num2str(Names(k))];
        title(titlename2);
        savenames2=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\Accel.
        Filtered ',num2str(Names(k)),'.pdf'];
        saveas(gcf,savenames2);
    else
        Afilter=[Afilter zeros(distmin*npeaksmax,1)];
        tfilter=[tfilter zeros(distmin*npeaksmax,1)];
    end
    else
        Afilter=[Afilter zeros(distmin*npeaksmax,1)];
        tfilter=[tfilter zeros(distmin*npeaksmax,1)];
    end
    hold off
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%TRANSFORMADA DE FOURIER%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

nensayos=47;

```

```

matrizintervalos=zeros(nensayos,2);
matrizintervalos=[1 2500;1250 3750;2500 5000;3750 6250;5000 7500;6250
8750;7500 10000;
8750 11250;10000 12500;11250 13750;12500 15000; 13750 16250;15000
17500;16250 18750;17500 20000;
18750 21250;20000 22500;21250 23750;22500 25000;23750 26250;25000
27500;26250 28750;27500 30000;
28750 31250;30000 32500;31250 33750;32500 35000;33750 36250;35000
37500;36250 38750;37500 40000;
38750 41250;40000 42500;41250 43750;42500 45000;43750 46250;45000
47500;46250 48750;47500 50000;
48750 51250;50000 52500;51250 53750;52500 55000;53750 56250;55000
57500;56250 58750;57500 60000];
matrizmax=zeros(nensayos,2);
periodo_muestreo=0.01;%en T
hold off
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%TRANSFORMADA COMPLETA%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
k=1;
for k=1:length(InformeAcel)
if InformeAcel(1,k)==1
i=1;
M=zeros(nensayos,3);
for i=1:nensayos
senal=A(matrizintervalos(i,1):matrizintervalos(i,2),k);
longitud_senal=length(senal);
%%Calculo
[Y_fft f_fft]=transformadafourier(senal);
NFFT = 2^nextpow2(longitud_senal);
matriz(:,1)=2*abs(Y_fft(1:NFFT/2));
matriz(:,2)=f_fft;
amplitud=matriz(:,1);
herzios=matriz(:,2);
[~,loc]=max(amplitud);
freq_max_aux1= matriz(loc,2);
amplitud(loc)= (0);
herzios(loc)= (0);
[val,loc]=max(amplitud);
freq_max_aux2= herzios(loc);
amplitud(loc)= (0);
herzios(loc)= (0);
[val,loc]=max(amplitud);
freq_max_aux3= herzios(loc);
frec1=freq_max_aux1;
frec2=freq_max_aux2;
frec3=freq_max_aux3;
M(i,1)=frec1;
M(i,2)=frec2;
M(i,3)=frec3;
%%Pinta la transformada
plot(f_fft,2*abs(Y_fft(1:NFFT/2)),'r') %2D
hold on
grid on
ylabel('Frecuencia [Hz]')
zlabel('|Y(f)|')
titlename3=['FFT aceleración ',num2str(Nombres(k))];
title(titlename3);
end
hold on
%%Vector de las tres primeras frecuencias para el acelerómetro
en el ensayo
pruebax=f_fft;

```

```

pruebay=2*abs(Y_fft(1:NFFT/2));
matrizfrecuencias(k,1)=mode(M(:,1));
POINT1=find(M==mode(M(:,1)));
matrizfrecuencias(k,2)=mode(M(:,2));
POINT2=find(M==mode(M(:,2)));
matrizfrecuencias(k,3)=mode(M(:,3));
POINT3=find(M==mode(M(:,3)));
plot(M(POINT1,1),'*')

savenames3=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\AccelerationFF
T',num2str(Names(k)),'ensayo.pdf'];
saveas(gcf,savenames3);
hold off

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%TRANSFORMADA DE CADA TRAMO%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
if npeaksfilter>0
u=1;
for u=1:npeaksfilter
senalfilter=Afilter((u*distmin-distmin+1):distmin*u),k);
longitud_senalfilter=length(senalfilter);
%%Calculo
[Y_fftfiler
f_fftfiler]=transformadafourier_v02(senalfilter);
NFFT = 2^nextpow2(longitud_senalfilter);
matrizf(:,1)=2*abs(Y_fftfiler(1:NFFT/2));
matrizf(:,2)=f_fftfiler;
amplitud=matrizf(:,1);
herzios=matrizf(:,2);
[~,loc]=max(amplitud);
freq_max_aux1= matrizf(loc,2);
amplitud(loc)= (0);
herzios(loc)= (0);
[val,loc]=max(amplitud);
freq_max_aux2= herzios(loc);
amplitud(loc)= (0);
herzios(loc)= (0);
[val,loc]=max(amplitud);
freq_max_aux3= herzios(loc);
frec1=freq_max_aux1;
frec2=freq_max_aux2;
frec3=freq_max_aux3;
M(i,1)=frec1;
M(i,2)=frec2;
M(i,3)=frec3;
%%Pinta la transformada
z=linspace(0.999*u,1.001*u,NFFT/2);plot3(z,f_fftfiler,(2*abs(Y_fftfil
ter(1:NFFT/2)))) %3D
hold on
grid on
ylabel('Frecuencia [Hz]')
zlabel('|Y(f)|')
titlename4=['FFT aceleración ',num2str(Names(k)),'Filtered'];
title(titlename4);
end
%%Vector de las tres primeras frecuencias para el acelerómetro
en el ensayo
matrizfrecuenciasfiltered(k,1)=mode(M(:,1));
matrizfrecuenciasfiltered(k,2)=mode(M(:,2));
matrizfrecuenciasfiltered(k,3)=mode(M(:,3));

```

```

savenames4=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\Accel.Filtered
FFT',num2str(Names(k)),'ensayo.pdf'];
    saveas(gcf,savenames4);
    end
    hold off
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%PINTAMOS FRECUENCIAS PRINCIPALES%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
grid on
grid minor
ph=1;
for ph=1:3
z=linspace(0.999*ph,1.001*ph,24);c=linspace(ph*0.9999,ph*1.0001,length
(z));y=linspace(0,24,24);s=75;
scatter3(y,z,matrizfrecuencias(:,ph),s,c) %3D
hold on
end
ph=1;
for ph=1:3
z=linspace(0.999*ph,1.001*ph,24);c=linspace(ph*0.9999,ph*1.0001,length
(z));y=linspace(0,24,24);s=25;
scatter3(y,z,matrizfrecuenciasfiltered(:,ph),s,c,'filled') %3D
hold on
end
xlabel('Frecuencia [Hz]')
ylabel('Frecuencias Principales(1,2,3)')
xlabel('Fases Acel. (1 a 24)')
titlename5=['Medida ',num2str(infomedida),' Comp. Frecuencias'];
title(titlename5);
hold off
savenames5=['D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\Medida',num2st
r(infomedida),'Comp.Frecuencias.pdf'];
saveas(gcf,savenames5);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%AÑADIMOS EN LA MATRIZ VALORES DE T y H%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
matrizfrecuenciasb=[matrizfrecuencias VInformeTemperatura
VInformeHumedad];
matrizfrecuenciasf=[matrizfrecuenciasfiltered VInformeTemperatura
VInformeHumedad];
save('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\matrizfrecuenciasb.ma
t','matrizfrecuenciasb');
save('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\matrizfrecuenciasf.ma
t','matrizfrecuenciasf');
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MOVEMOS vectorfrecuencias Y vectorfrecuenciasfiltered%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
cd 'D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL'
copyfile('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\matrizfrecuencias
b.mat','D:\UNICAN\TFM\Propio_2\VFREC')
copyfile('D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL\matrizfrecuencias
f.mat','D:\UNICAN\TFM\Propio_2\VFREC')
cd 'D:\UNICAN\TFM\Propio_2\VFREC'
if infomedida>99
vectorfr=['matrizfrecuenciasb',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasb.mat",vectorfr)
vectorfrf=['matrizfrecuenciasf',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasf.mat",vectorfrf)
elseif infomedida>9
vectorfr=['matrizfrecuenciasb0',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasb.mat",vectorfr)

```

```

vectorfrf=['matrizfrecuenciasf0',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasf.mat",vectorfrf)
else
vectorfr=['matrizfrecuenciasb00',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasb.mat",vectorfr)
vectorfrf=['matrizfrecuenciasf00',num2str(infomedida),'.mat'];
movefile("matrizfrecuenciasf.mat",vectorfrf)
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MOVEMOS RESULTADOS A LA MEDIDA CORRESPONDIENTE%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
cd 'D:\UNICAN\TFM\Propio_2\RESULTADOS'
if infomedida>99
fichero=['MEDIDA ',num2str(infomedida)];
movefile("TEMPORAL",fichero)
elseif infomedida>95
fichero=['MEDIDA 0',num2str(infomedida)];
movefile("TEMPORAL",fichero)
else
fichero=['MEDIDA 00',num2str(infomedida)];
movefile("D:\UNICAN\TFM\Propio_2\RESULTADOS\TEMPORAL",fichero)
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
close all
cd 'D:\UNICAN\TFM\Propio_2'
end

```

II. DISPERSIÓN DE RESULTADOS

Con el siguiente script obtenemos la representación gráfica de todos los valores anteriormente calculados para observar y comprobar los resultados entre obtener las frecuencias principales utilizando toda la señal o solamente los tramos filtrados por la secuencia de picos.

```

function Dispersion
close all
ar=ls("D:\UNICAN\TFM\Propio_2\VFREC");ar=ar(3:end,:);
s=size(ar);s=s(1);
Mfr1=[];Mfr2=[];Mfr3=[];
j=1;x=linspace(1,8,24)';sz=15;
for j=1:(s/2)
ad=['D:\UNICAN\TFM\Propio_2\VFREC\'',num2str(ar(j,:))];
carga=importdata(ad);
fr1=carga(:,1);Mfr1=[Mfr1 fr1];
fr2=carga(:,2);Mfr2=[Mfr2 fr2];
fr3=carga(:,3);Mfr3=[Mfr3 fr3];
subplot(3,2,1)
grid,grid minor
hold on
plot(x,fr1,'o')
xlabel('Acel. 8X3')
ylabel('Frecuencia')
title('1° MODO COMPLETO')
subplot(3,2,3)
grid,grid minor
hold on
scatter(x,fr2,sz)
xlabel('Acel. 8X3')
ylabel('Frecuencia')
title('2° MODO COMPLETO')

```



```

        subplot(3,2,5)
        grid,grid minor
        hold on
        scatter(x,fr3,sz)
        xlabel('Acel. 8X3')
        ylabel('Frecuencia')
        title('3° MODO COMPLETO')
    end

    x=linspace(1,8,24)';sz=15;
    Mfr1f=[];Mfr2f=[];Mfr3f=[];
    for j=(s/2+1):s
        ad=['D:\UNICAN\TFM\Propio_2\VFREC\'',num2str(ar(j,:))];
        carga=importdata(ad);
        fr1f=carga(:,1);Mfr1f=[Mfr1f fr1f];
        fr2f=carga(:,2);Mfr2f=[Mfr2f fr2f];
        fr3f=carga(:,3);Mfr3f=[Mfr3f fr3f];

        subplot(3,2,2)
        grid,grid minor
        hold on
        plot(x,fr1f,'o')
        xlabel('Acel. 8X3')
        ylabel('Frecuencia')
        title('1° MODO FILTRADO')
        subplot(3,2,4)
        grid,grid minor
        hold on
        scatter(x,fr2f,sz)
        xlabel('Acel. 8X3')
        ylabel('Frecuencia')
        title('2° MODO FILTRADO')
        subplot(3,2,6)
        grid,grid minor
        hold on
        scatter(x,fr3f,sz)
        xlabel('Acel. 8X3')
        ylabel('Frecuencia')
        title('3° MODO FILTRADO')
    end

    saveas(gcf,'D:\UNICAN\TFM\Propio_2\DISPERSION\Dispersion.pdf');
end

```

III. CÁLCULO DE CORRELACIONES

Este script se utiliza en la etapa del estudio estadístico para obtener el grado de correlación entre los acelerómetros fijos y variables en las 3 fases de medición.

```

function Correlation
infomedida=1;
iniciomedida=1;
finalmedida=110;
InformeFase=1;
lf1=29;lf2=110-29;lf3=195-169;
%%%%%%%%%%%%CARGAMOS TODAS LAS MATRICES DE FRECUENCIAS%%%%%%%%%%%%
Macum=[];Mfija=zeros(6,3*finalmedida);
for infomedida=iniciomedida:finalmedida;

```

```

cd 'D:\UNICAN\TFM\Propio_2\VFREC'
if infomedida>99
mul=['matrizfrecuenciasf',num2str(infomedida)];
load(mul)
elseif infomedida>9
mul=['matrizfrecuenciasf0',num2str(infomedida)];
load(mul)
else
mul=['matrizfrecuenciasf00',num2str(infomedida)];
load(mul)
end
cd 'D:\UNICAN\TFM\Propio_2'
Macum=[Macum matrizfrecuenciasf(:, [1:3])];
end

%SEPARAMOS POR FRECUENCIAS
z=1;MFr1=[];MFr2=[];MFr3=[];
for k=1:110
MFr1=[MFr1 Macum(:, z)];
MFr2=[MFr2 Macum(:, (z+1))];
MFr3=[MFr3 Macum(:, (z+2))];
z=z+3;
end

%MFr1: Matriz de frecuencias (1)    24 x 195
%MFr2: Matriz de frecuencias (2)    24 x 195
%MFr3: Matriz de frecuencias (3)    24 x 195

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%SEPARAMOS POR FASE Y POSICION%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%FASE 1%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MFr1f1=MFr1([1:18],[1:(29)]);
MFr2f1=MFr2([1:18],[1:(29)]);
MFr3f1=MFr3([1:18],[1:(29)]);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%FASE 2%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MFr1f2=MFr1([1:18],[ (29+1):(110)]);
MFr2f2=MFr2([1:18],[ (29+1):(110)]);
MFr3f2=MFr3([1:18],[ (29+1):(110)]);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%FASE 3%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MFr1f3=MFr1([1:18],[ (169+1):(195)]);
MFr2f3=MFr2([1:18],[ (169+1):(195)]);
MFr3f3=MFr3([1:18],[ (169+1):(195)]);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%FIJA%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
MFr1fija=MFr1([19:24],:);
MFr2fija=MFr2([19:24],:);
MFr3fija=MFr3([19:24],:);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%COVARIANZAS:cada eje de los acel. con los fijos de ese EJE%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
aux1=[1:18,1:18];
w1=[1 2 3];w2=[4 5 6];
aux2=[w1 w1 w1 w1 w1 w2 w2 w2 w2 w2 w2];
MATRIZ_r=[];
MATRIZ_R=[];
k=1;
for k=1:36;
covarianza_Fr1_f1=[];covarianza_Fr2_f1=[];covarianza_Fr3_f1=[];
covarianza_Fr1_f2=[];covarianza_Fr2_f2=[];covarianza_Fr3_f2=[];
covarianza_Fr1_f3=[];covarianza_Fr2_f3=[];covarianza_Fr3_f3=[];

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MATRIZ DE COVARIANZAS FASE 1%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
covarianza_Fr1_f1=cov(MFr1f1(aux1(k),:),MFr1fija(aux2(k),[1:29]));
covarianza_Fr2_f1=cov(MFr2f1(aux1(k),:),MFr2fija(aux2(k),[1:29]));

```

```

covarianza_Fr3_f1=cov(MFr1f1(aux1(k),:),MFr3fija(aux2(k),[1:29]));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MATRIZ DE COVARIANZAS FASE 2%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
covarianza_Fr1_f2=cov(MFr1f2(aux1(k),:),MFr1fija(aux2(k),[30:110]));
covarianza_Fr2_f2=cov(MFr1f2(aux1(k),:),MFr2fija(aux2(k),[30:110]));
covarianza_Fr3_f2=cov(MFr1f2(aux1(k),:),MFr3fija(aux2(k),[30:110]));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MATRIZ DE COVARIANZAS FASE 3%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%covarianza_Fr1_f3=cov(MFr1f3(aux1(k),:),MFr1fija(aux2(k),[170:195]));
%covarianza_Fr2_f3=cov(MFr1f3(aux1(k),:),MFr1fija(aux2(k),[170:195]));
%covarianza_Fr3_f3=cov(MFr1f3(aux1(k),:),MFr1fija(aux2(k),[170:195]));
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%FREC 1, FASE 1
lxx_Fr1_f1=covarianza_Fr1_f1(1,1);lyy_Fr1_f1=covarianza_Fr1_f1(2,2);
lxy_Fr1_f1=covarianza_Fr1_f1(1,2);lyx_Fr1_f1=covarianza_Fr1_f1(2,1);
%%FREC 1, FASE 2
lxx_Fr1_f2=covarianza_Fr1_f2(1,1);lyy_Fr1_f2=covarianza_Fr1_f2(2,2);
lxy_Fr1_f2=covarianza_Fr1_f2(1,2);lyx_Fr1_f2=covarianza_Fr1_f2(2,1);
%%FREC 1, FASE 3
%lxx_Fr1_f3=covarianza_Fr1_f3(1,1);lyy_Fr1_f3=covarianza_Fr1_f3(2,2);
%lxy_Fr1_f3=covarianza_Fr1_f3(1,2);lyx_Fr1_f3=covarianza_Fr1_f3(2,1);
%%FREC 2, FASE 1
lxx_Fr2_f1=covarianza_Fr2_f1(1,1);lyy_Fr2_f1=covarianza_Fr2_f1(2,2);
lxy_Fr2_f1=covarianza_Fr2_f1(1,2);lyx_Fr2_f1=covarianza_Fr2_f1(2,1);
%%FREC 2, FASE 2
lxx_Fr2_f2=covarianza_Fr2_f2(1,1);lyy_Fr2_f2=covarianza_Fr2_f2(2,2);
lxy_Fr2_f2=covarianza_Fr2_f2(1,2);lyx_Fr2_f2=covarianza_Fr2_f2(2,1);
%%FREC 2, FASE 3
%lxx_Fr2_f3=covarianza_Fr2_f3(1,1);lyy_Fr2_f3=covarianza_Fr2_f3(2,2);
%lxy_Fr2_f3=covarianza_Fr2_f3(1,2);lyx_Fr2_f3=covarianza_Fr2_f3(2,1);
%%FREC 3, FASE 1
lxx_Fr3_f1=covarianza_Fr3_f1(1,1);lyy_Fr3_f1=covarianza_Fr3_f1(2,2);
lxy_Fr3_f1=covarianza_Fr3_f1(1,2);lyx_Fr3_f1=covarianza_Fr3_f1(2,1);
%%FREC 3, FASE 2
lxx_Fr3_f2=covarianza_Fr3_f2(1,1);lyy_Fr3_f2=covarianza_Fr3_f2(2,2);
lxy_Fr3_f2=covarianza_Fr3_f2(1,2);lyx_Fr3_f2=covarianza_Fr3_f2(2,1);
%%FREC 3, FASE 3
%lxx_Fr3_f3=covarianza_Fr3_f3(1,1);lyy_Fr3_f3=covarianza_Fr3_f3(2,2);
%lxy_Fr3_f3=covarianza_Fr3_f3(1,2);lyx_Fr3_f3=covarianza_Fr3_f3(2,1);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%MATRIZ DE CORRELACIONES%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
r78_Fr1_f1=lxy_Fr1_f1^2/(lxx_Fr1_f1*lyy_Fr1_f1);R78_Fr1_f1=lxy_Fr1_f1/
(sqrt(lxx_Fr1_f1*lyy_Fr1_f1));
r78_Fr1_f2=lxy_Fr1_f2^2/(lxx_Fr1_f2*lyy_Fr1_f2);R78_Fr1_f2=lxy_Fr1_f2/
(sqrt(lxx_Fr1_f2*lyy_Fr1_f2));
%r78_Fr1_f3=lxy_Fr1_f3^2/(lxx_Fr1_f3*lyy_Fr1_f3);R78_Fr1_f3=lxy_Fr1_f3/
(sqrt(lxx_Fr1_f3*lyy_Fr1_f3));
r78_Fr2_f1=lxy_Fr2_f1^2/(lxx_Fr2_f1*lyy_Fr2_f1);R78_Fr2_f1=lxy_Fr2_f1/
(sqrt(lxx_Fr2_f1*lyy_Fr2_f1));
r78_Fr2_f2=lxy_Fr2_f2^2/(lxx_Fr2_f2*lyy_Fr2_f2);R78_Fr2_f2=lxy_Fr2_f2/
(sqrt(lxx_Fr2_f2*lyy_Fr2_f2));
%r78_Fr2_f3=lxy_Fr2_f3^2/(lxx_Fr2_f3*lyy_Fr2_f3);R78_Fr2_f3=lxy_Fr2_f3/
(sqrt(lxx_Fr2_f3*lyy_Fr2_f3));
r78_Fr3_f1=lxy_Fr3_f1^2/(lxx_Fr3_f1*lyy_Fr3_f1);R78_Fr3_f1=lxy_Fr3_f1/
(sqrt(lxx_Fr3_f1*lyy_Fr3_f1));
r78_Fr3_f2=lxy_Fr3_f2^2/(lxx_Fr3_f2*lyy_Fr3_f2);R78_Fr3_f2=lxy_Fr3_f2/
(sqrt(lxx_Fr3_f2*lyy_Fr3_f2));
%r78_Fr3_f3=lxy_Fr3_f3^2/(lxx_Fr3_f3*lyy_Fr3_f3);R78_Fr3_f3=lxy_Fr3_f3/
(sqrt(lxx_Fr3_f3*lyy_Fr3_f3));
MATRIZ_r=[MATRIZ_r;r78_Fr1_f1 r78_Fr2_f1 r78_Fr3_f1 r78_Fr1_f2
r78_Fr2_f2 r78_Fr3_f2]; %r78_Fr1_f3 r78_Fr2_f3 r78_Fr3_f3];

```

```

MATRIZ_R=[MATRIZ_R;R78_Fr1_f1 R78_Fr2_f1 R78_Fr3_f1 R78_Fr1_f2
R78_Fr2_f2 R78_Fr3_f2]; %R78_Fr1_f3 R78_Fr2_f3 R78_Fr3_f3];
%%MATRIZ_r:36x9:
%18x9(reacciones sobre Acel 7) + 18x9(reacciones sobre Acel 8)
End

NamesA7=["A7 Fase1 frec1" "A7 Fase1 frec2" "A7 Fase1 frec3" "A7 Fase2
frec1" "A7 Fase2 frec2" "A7 Fase2 frec3"];% "A7 Fase3 frec1" "A7 Fase3
frec2" "A7 Fase3 frec3"];
NamesA8=["A8 Fase1 frec1" "A8 Fase1 frec2" "A8 Fase1 frec3" "A8 Fase2
frec1" "A8 Fase2 frec2" "A8 Fase2 frec3"]; %"A8 Fase3 frec1" "A8 Fase3
frec2" "A8 Fase3 frec3"];
SaveA7=["Fase1_frec1_A7" "Fase1_frec2_A7" "Fase1_frec3_A7"
"Fase2_frec1_A7" "Fase2_frec2_A7" "Fase2_frec3_A7"];% "Fase3_frec1_A7"
"Fase3_frec2_A7" "Fase3_frec3_A7"];
SaveA8=["Fase1_frec1_A8" "Fase1_frec2_A8" "Fase1_frec3_A8"
"Fase2_frec1_A8" "Fase2_frec2_A8" "Fase2_frec3_A8"];% "Fase3_frec1_A8"
"Fase3_frec2_A8" "Fase3_frec3_A8"];

%Representamos Valores
%%%%%%%%%%FASE 1%%%%%%%%%%
for v=1:6
figure
plot(MATRIZ_R([1:18],v),'r*')
xlim([1 18])
grid
grid minor
titlename=['Grado de correlación sobre ',num2str(NamesA7(v))];
title(titlename);
savename=['D:\UNICAN\TFM\Propio_2\CORRELACION\',num2str(SaveA7(v)),'.p
df'];
saveas(gcf,savename);
savename=['D:\UNICAN\TFM\Propio_2\CORRELACION\',num2str(SaveA7(v)),'.p
ng'];
saveas(gcf,savename);

figure
plot(MATRIZ_R([19:36],v),'b*')
xlim([1 18])
grid
grid minor
titlename=['Grado de correlación sobre ',num2str(NamesA8(v))];
title(titlename);
savename=['D:\UNICAN\TFM\Propio_2\CORRELACION\',num2str(SaveA8(v)),'.p
df'];
saveas(gcf,savename);
savename=['D:\UNICAN\TFM\Propio_2\CORRELACION\',num2str(SaveA8(v)),'.p
ng'];
saveas(gcf,savename);
end

%INPUTS MODELO ESTADÍSTICO
MATRIZ_R_FASE1=MATRIZ_R(:, [1:3]);MATRIZ_R_FASE1=[MATRIZ_R_FASE1([1:18]
,:),MATRIZ_R_FASE1([19:end],:)];
%MATRIZ_R_FASE1: matriz de las 3 frecuencias
MATRIZ_R_FASE1_fr1=[MATRIZ_R_FASE1(:,1) MATRIZ_R_FASE1(:,4)];
A7_R_FASE1_fr1=MATRIZ_R_FASE1_fr1(:,1);
A8_R_FASE1_fr1=MATRIZ_R_FASE1_fr1(:,2);

```

```

bv=ones(29,1);
MFr1fijaFASE1=MFr1fija(:,[1:29])
R17X=A7_R_FASE1_fr1(1)*bv;
R17Y=A7_R_FASE1_fr1(2)*bv;
R47Z=A7_R_FASE1_fr1(12)*bv;

R18Y=A7_R_FASE1_fr1(2)*bv;
R48Y=A7_R_FASE1_fr1(11)*bv;
R48Z=A7_R_FASE1_fr1(12)*bv;
R68X=A7_R_FASE1_fr1(16)*bv;
R68Y=A7_R_FASE1_fr1(17)*bv;

A1X=MFr1f1(1,:);A1X=A1X';
A1Y=MFr1f1(2,:);A1Y=A1Y';
A4Z=MFr1f1(12,:);A4Z=A4Z';
A4Y=MFr1f1(11,:);A4Y=A4Y';
A6X=MFr1f1(16,:);A6X=A6X';
A6Y=MFr1f1(17,:);A6Y=A6Y';

A7X=MFr1fijaFASE1(1,:);A7X=A7X';
A7Y=MFr1fijaFASE1(2,:);A7Y=A7Y';
A7Z=MFr1fijaFASE1(3,:);A7Z=A7Z';

A8X=MFr1fijaFASE1(4,:);A8X=A8X';
A8Y=MFr1fijaFASE1(5,:);A8Y=A8Y';
A8Z=MFr1fijaFASE1(6,:);A8Z=A8Z';

INPUT_RED=[A1X,R17X,A7X,A1Y,R17Y,A7Y,A4Z,R47Z,A7Z,A1Y,R18Y,A8Y,A4Y,R48
Y,A8Y,A4Z,R48Z,A8Z,A6X,R68X,A8X,A6Y,R68Y,A8Y]
INPUT_RED=INPUT_RED';
xlswrite('D:\UNICAN\TFM\Propio_2\Correlaciones.xlsx',INPUT_RED,'INPUT
RED','c5:z33')
MFr1f1=MFr1f1';MFr1fijaFASE1=MFr1fijaFASE1';
xlswrite('D:\UNICAN\TFM\Propio_2\Correlaciones.xlsx',MFr1f1,'PANDAS','
a2:r30')
xlswrite('D:\UNICAN\TFM\Propio_2\Correlaciones.xlsx',MFr1fijaFASE1,'PA
NDAS','s2:x30')
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

IV. MODELO ESTADISTICO

Para modelar el sistema de SHM se ha utilizado la herramienta Colaboratory (lenguaje Python) con el script siguiente:

```
from sklearn.datasets import make_regression
from sklearn.multioutput import MultiOutputRegressor
from sklearn.ensemble import GradientBoostingRegressor
from sklearn.linear_model import LinearRegression

import pandas as pd
from pandas import ExcelWriter
from pandas import ExcelFile

df7 = pd.read_excel('Montecarlo_V02.xlsx', sheet_name='INPUT COLAB
A7')

df8 = pd.read_excel('Montecarlo_V02.xlsx', sheet_name='INPUT COLAB
A8')

print("Column headings:")
print(df7.columns)#Acelerómetro A7
print(df8.columns)#Acelerómetro A8

##### ACELERÓMETRO 7 #####
#Valores de entrenamiento (training)
A1xt=df7.iloc[0:120,0:1];A1yt=df7.iloc[0:120,1:2];
A3zt=df7.iloc[0:120,2:3];A4zt=df7.iloc[0:120,3:4];
A7xt=df7.iloc[0:120,4:5];A7yt=df7.iloc[0:120,5:6];A7zt=df7.iloc[0:1
20,6:7]

#Valores de validación (testing)
A1xv=df7.iloc[120:171,0:1];A1yv=df7.iloc[120:171,1:2];
A3zv=df7.iloc[120:171,2:3];A4zv=df7.iloc[120:171,3:4];
A7xv=df7.iloc[120:171,4:5];A7yv=df7.iloc[120:171,5:6];A7zv=df7.iloc
[120:171,6:7]
```

```

A34zt=df7.iloc[0:120,2:4];A34zv=df7.iloc[120:171,2:4]; # A3z y A4z
juntos sobre A7z

pred_A7x =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A1xt, A7xt).predict(A1xv)

pred_A7y =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A1yt, A7yt).predict(A1yv)

pred_A7z =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A34zt, A7zt).predict(A34zv)

print("Predictions (A7) A1x: ", pred_A7x)
print("Predictions (A7) A1y: ", pred_A7y)
print("Predictions (A7) A34z: ", pred_A7z)

##### ACELERÓMETRO 8 #####
#Valores de entrenamiento (training)
A1xt=df8.iloc[0:120,0:1];A6xt=df8.iloc[0:120,1:2];
A1yt=df8.iloc[0:120,2:3];A4yt=df8.iloc[0:120,3:4];
A6yt=df8.iloc[0:120,4:5];A1zt=df8.iloc[0:120,5:6];
A4zt=df8.iloc[0:120,6:7];A8xt=df8.iloc[0:120,7:8];
A8yt=df8.iloc[0:120,8:9];A8zt=df8.iloc[0:120,9:10];

#Valores de validación (testing)
A1xv=df8.iloc[120:171,0:1];A6xv=df8.iloc[120:171,1:2];
A1yv=df8.iloc[120:171,2:3];A4yv=df8.iloc[120:171,3:4];
A6yv=df8.iloc[120:171,4:5];A1zv=df8.iloc[120:171,5:6];
A4zv=df8.iloc[120:171,6:7];A8xv=df8.iloc[120:171,7:8];
A8yv=df8.iloc[120:171,8:9];A8zv=df8.iloc[120:171,9:10];

A16xt=df8.iloc[0:120,0:2];A16xv=df8.iloc[120:171,0:2]; # A1x y A6x
juntos sobre A8x

A146yt=df8.iloc[0:120,2:5];A146yv=df8.iloc[120:171,2:5]; # A1y A4y
y A6y juntos sobre A8y

```

```

A14zt=df8.iloc[0:120,5:7];A14zv=df8.iloc[120:171,5:7]; # A1z y A4z
juntos sobre A8z

pred_A8x =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A16xt, A8xt).predict(A16xv)

pred_A8y =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A146yt, A8yt).predict(A146yv)

pred_A8z =
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit
(A14zt, A8zt).predict(A14zv)

print("Predictions (A8) A16x: ", pred_A8x)
print("Predictions (A8) A146y: ", pred_A8y)
print("Predictions (A8) A14z: ", pred_A8z)

#print(pred_A8x-A8xv)

#df=pred_A7x
#,pred_A7y,pred_A7z,pred_A8x,pred_A8y,pred_A8z)
#print(df2)

#writer = pd.ExcelWriter('OUTPUT COLAB.xlsx')
#df.to_excel(writer)
#writer.save()

A16x_ALARMA=3*df8.iloc[80:81,0:2];
A146y_ALARMA=3*df8.iloc[80:81,2:5];
A14z_ALARMA=3*df8.iloc[80:81,5:7];
print("ALARMA_X", A16x_ALARMA)
print("ALARMA_Y", A146y_ALARMA)
print("ALARMA_Z", A14z_ALARMA)
#from google.colab import files
#files.download('OUTPUT COLAB.xlsx')

```



```
pred_A8x_ALARMA =  
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit  
(A16xt, A8xt).predict(A16x_ALARMA)  
  
pred_A8y_ALARMA =  
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit  
(A146yt, A8yt).predict(A146y_ALARMA)  
  
pred_A8z_ALARMA =  
MultiOutputRegressor(GradientBoostingRegressor(random_state=0)).fit  
(A14zt, A8zt).predict(A14z_ALARMA)  
  
print("ALARMA (A8) A16x: ", pred_A8x_ALARMA)  
print("ALARMA (A8) A146y: ", pred_A8y_ALARMA)  
print("ALARMA (A8) A14z: ", pred_A8z_ALARMA)
```

ANEXO II: DISEMINACIÓN E IMPACTO CIENTÍFICO

Gradient-Boosting applied for proactive maintenance system in a railway bridge

Francisco Iglesias¹, David García-Sánchez ²[0000-0002-4763-206X], Jesus Diez², Iñaki Piñero², Ana Fernández-Navamuel², Diego Zamora Sánchez² and José Carlos Jiménez-Fernandez²

¹ University of Cantabria, Avda. de los Castros, s/n 39005 Santander, Spain

² TECNALIA, Basque Research and Technology Alliance (BRTA), Parque Científico y Tecnológico de Bizkaia Astondo bidea Edificio 700, E-48160 Derio, Spain

david.garciasanchez@tecnalia.com

Abstract. This article contributes in the research direction of the application of Machine Learning techniques in bridge safety assessment and it lays basis to further improve the accuracy of safety assessment including real data analysis.

The communication puts forward the process and model of scale measured points correlation of bridge monitoring system on the frequency domain as a tactic to control the influence of a railway device (crossing) located on the top deck of a railway bridge. The process and model are put forward mainly for the characteristics of the damage detection for a long-term structure assessment going from an intensive multi-sensor monitoring system to a softer one. Finally, a Gradient-Boosting multi-regressor method has been developed to be easily implemented in a warning system providing predictive skills to the current preventive maintenance strategy. The method is validated by simulating the undamaged and abnormal scenarios with Monte Carlo.

Keywords: Gradient-Boosting, Correlation, Multi-sensor, Bridge.

1 Introduction

The objective of this paper is to present a damage detection tool induced on a Railway Bridge by the passage of actual circulations over a crossing [1] in its trace. To this end, the acceleration data obtained by monitoring has been used and the techniques of recognizing statistical patterns have been used, which allow to solve a simple classification problem between two possible states: the damaged and the non-damaged. The bridge on which the study is being developed has an important uniqueness: a crossing on its trace which carries a risk of amplifying the dynamic response of the bridge to a malfunction or adjustment of such device. A field work phase has been carried out where 8 triaxial accelerometers have been placed along the structure and in variable positions. These collected data were processed in order to be able to recognize patterns of behavior and, once these patterns were recognized, a statistical model based on Gradient Boosting was developed.

1.1 Description of the structure

The bridge is located in Bilbao (Spain). It was built in 2002 and is made of reinforced and pre-tensioned concrete. It consists of 3 continuous units. The first one is a 5 spans ($22.0\text{ m} + 3 \times 24.5\text{ m} + 24.0\text{ m}$) that connect to a double arch over the Nervion River (second unit) and a final 12 meters' span connecting to a nearby tunnel (third unit).

Finally, it is necessary to mention that the fixed point against horizontal forces (longitudinal and transverse) is located in the center of the arc length. The main features of the bridge are shown below:




Fig. 1. Description of the structure (Bolueta bridge, Bilbao).

The bridge under study fits into a vertical and horizontal agreement curve (Fig. 1). This bridge has an unconventional structural design and also has a crossing located on the center of the arch. Because of this, it is a point of great interest to study the dynamic behavior of the structure at the passage of trains.

1.2 Objective

The measurement step was structured in 3 different phases, where the accelerometers were relocated to different positions of the bridge with the idea of being able to know the vibrations generated in all parts of the deck and their correlation with the vibrations in the area of the crossing. In each phase 8 accelerometers were placed, of which 2 of them did not vary their position (fixed accelerometers). These accelerometers were placed on the deck in the crossing area.




Fig. 2. Scheme for the placement of accelerometers and measurement phases.

The rest (6) varied their position (moving accelerometers) depending on the measurement phase. In addition, temperature and humidity sensors were available. The following image (Fig. 2) shows the exact location of the sensors and the different phases by colors.

1.3 Monitoring system

The complete monitoring system consisted of 8 accelerometers (trixials), 2 clinometers (bi-axial) and temperature (°C) and humidity (%). Two data loggers with 16 input channels were used for data measurement. Solar panels were installed as a power supply complement as a power equipment. The collected data was sent to a central server via a 4G router. The generated data files were sorted into packages or 10-minute windows taking into account the railway's operating hours.

A total of 195 measurements were made in sync with the trains' passing times. Each measurement recorded acceleration data on each of the axes (X, Y, Z) for

600 seconds. The 195 measurements were divided into 3 campaigns leaving 2 accelerometers fixed and repositioning the rest, as detailed in Fig. 2. The sampling rate was 100 Hz, i.e. 60000 discrete samples of the accelerations experienced by the bridge were recorded in each one.

2 Preprocess

At this step different filters and smoothing techniques were applied until the main frequencies of the structure were obtained.

Due to the excessive volume of starting data, a statistical study of the data was necessary to reduce the amount of information to work with to ensure the robustness of subsequent models.

2.1 Sensor selection and Data cleansing

A first study of the measurements discarded those accelerometers whose measurement was not correct [2], or had drift to the extent. This will result in each measurement of each phase (X, Y, Z) of each accelerometer based on time.

Because measurements were taken according to the bridge's usage schedule, results were obtained with a background noise of the structure interrupted by impulses introduced by the passage of vehicles (in this case trains) along the structure. The amplitude and duration of these pulses (peaks) varied depending on the position of the accelerometer on the bridge and the type of measurement it performs (X, Y, Z).

2.2 Sample selection

To obtain the natural frequencies of the structure, the behaviour of the bridge subjected to free vibrations was studied, i.e. the bridge's response once the load or request ceases (when the train has left the bridge). This free vibration response practically corresponds to the signal section from the local maximum (peak) to the damping and integration with the background noise.

Once the peak detection algorithm was applied, it was able to select the sections on which to analyse the free oscillations and the main frequencies.

2.3 Frequency Domain: Fourier Analysis

Once the samples of interest already selected are available, the main frequencies of the structure associated with that excitation are calculated.

The outputs obtained at this pre-process stage are the first 3 frequencies for each accelerometer in each of the 195 measurements.

The code used allowed to extract the first 3 frequencies of the structure, although for physical clarity and simplicity of calculation was worked only with the first frequency. Taking into account the rigidity of such structures and the frequency of excitation of the loads, the vibration mode that appears or will be affected will be, almost exclusively, the first mode of vibration. Because the approach of the study is of the EMA (Experimental Modal Analysis) [3] [4], the approximation of the statistical study to the first mode of vibration is structurally justified.

In the field of maintenance of structures, less precision is usually needed as far as the numerical solution is concerned. But another factor must be taken into

account, the mode of excitation of the structure. Depending on the type of loads that produce the excitation, the bridge response will be associated with different vibration modes., for the case of study, the loads that produce the recorded signal are loads associated with the nominal operating regime of the bridge (step of the trains) and, therefore, the excitation mode of that structure shall be almost exclusive to the first mode of vibration as explained in [5]. Because of this the analysis carried out for this project is based on the EMA.

3 Statistical Study

3.1 Introduction

At this stage we address the extraction of series for the further development of the statistical model. The statistical study allows to take advantage of the information obtained in the monitoring process to evaluate the status of the structure. According to the approach set out in [6] the matrix of correlations (or covariance) is proposed as a starting point for developing a global diagnostic tool on the state of the structure to find out what the measurements are in the variable positions better correlation with measurements in fixed positions. In this way, only measures with the highest correlation coefficient R are selected for the development of the predictive model

3.2 Linear correlation analysis

During the monitoring process a sample of data was obtained that correspond to the undamaged state of the structure. In this type of studies it is advisable to normalize the data, especially when working with sensors of different nature. In this case no such standardization was necessary as the sensors are of the same type. In addition, each component of the data processed was worked independently, i.e. the 3 axes of accelerations (X, Y, Z) were not related to each other.

The procedure therefore involves calculating the variance and covariance values of the accelerometers variable to the fixed ones, resulting in covariance matrices for each component (X, Y, Z) of each main frequency (1st, 2nd, 3rd) of the 3 measurement phases for each fixed accelerometer placed.

The procedure follows the guidelines set out in [6] where expressions of the type are:

$$\sigma_{A1XA1X} = \sum_{i=1}^M (A1X_i - E(A1X))^2 / (M - 1) \quad (1)$$

$$\sigma_{A7XA7X} = \sum_{i=1}^M (A7X_i - E(A7X))^2 / (M - 1) \quad (2)$$

$$\sigma_{A1XA7X} = \sum_{i=1}^M (A1X_i - E(A1X))(A7X_i - E(A7X)) / (M - 1) \quad (3)$$

$$M\sigma = \begin{pmatrix} \sigma_{A1XA1X} & \sigma_{A1XA7X} \\ \sigma_{A1XA7X} & \sigma_{A7XA7X} \end{pmatrix} \quad (4)$$

$$r = \sigma_{A1XA7X}^2 / \sigma_{A1XA1X} \sigma_{A7XA7X} \quad (5)$$

$$R = \sigma_{A1XA7X} / \sqrt{\sigma_{A1XA1X} \sigma_{A7XA7X}} \quad (6)$$

Where Eqs (1), (2) and (3) are the parameters that make up the Eq Covariance Matrix (4).

The above equations show an example matrix of covariance obtained. This matrix studies the correlation between A1 (variable accelerometer) with the A7 (fixed accelerometer), and more specifically the X component. This results in a r and R (Eqs (5) and (6)) value of this component. Similarly, you would work with the Y and Z axis data. Similarly, the r and R parameters would be obtained for each variable accelerometer component that collect the degree of correlation between that variable accelerometer and the fixed accelerometer. As two fixed accelerometers (A7 and A8) are available, it will proceed similarly with the other accelerometer (A8) and its components (A8X, A8Y, A8Z).

Finally, as a result of the preprocessing and statistical study developed the initial sample of 195 records is reduced to 20.




Fig. 3. Correlation (indicator R) over A7 and A8.

4 Predictive model

4.1 Introduction

In this point the design of statistical models that allow the use of the available information of the monitoring process and the statistical study to provide the infrastructure manager with a predictive tool for bridge damage due to the influence of the crossing is developed.

Therefore, according to this approach, a classification algorithm between two states (damaged and undamaged) has been configured to assess the state of the structure globally and in real time. This procedure is based on unsupervised machine learning techniques, with only data available for the undamaged state of the structure. The confidence level has been set at 75%. These points will be used to train and validate the tool. In short, using the first frequency obtained in the preprocess, we will not only have the required precision, but it is justified due to the mode of excitation of the structure.

Table 1 and Fig. 4 show the accelerometers that will be used for training our tool.

	A7	A8		A7	A8
A1X	0.861	0.752	A3X		
A1Y	0.866	0.805	A3Y		
A1Z		0.797	A3Z	0.752	
A4X			A6X		0.857
A4Y		0.814	A6Y		0.855

A4Z	0.821	0.835	A6Z
-----	-------	-------	-----

Table 1. Correlation summary




Fig. 4. Inputs-Outputs for predictive modelling

4.2 Generation of additional synthetic data using Monte Carlo (synthetic benchmarking)

Because only 20 quality samples are available for the development of the SHM statistical model, additional data simulation has been carried out using Monte Carlo [7] analysis techniques in order to design a more robust model.

The tool is designed using the free Jupyter Notebook "Colaboratory" environment. The Collaborative tool, using Python language, allows you to work with almost any regression method applied to multi-response systems. This results in a total of 100 samples for each accelerometer that will be divided into two blocks:

Training phase: It will collect 70% of the samples obtained and serve to train our system.

Validation phase: It covers the remaining 30% of samples and will be used to check how reliable is the model obtained in the previous phase.

4.3 Multioutput Regressor: Gradient Boosting

The goal is to get a tool that is able to predict the response at any point of the bridge from the fixed accelerometers placed and compare with the actual measurement. This will trigger the alarm when the expected correlation (Damage Index) is lost.

The Gradient Boosting regression method [8] will be used in this work. This method is based on decision trees and groups their weak prediction models into a more robust joint system. It uses an algorithm that seeks to minimize gradient in iterations.

Once the validation sample is available, the procedure to follow is similar to that performed with the data in the original sample. The resulting frequency values in

fixed accelerometers (prediction values) will be calculated using the already trained Machine Learning tool. These obtained values will be compared with the values calculated by simulation, that is, the reference model. Synthetic alarm values are generated to test the tool.

To compare the results and check the level of accuracy of the tool to be implemented, the value obtained in the prediction of that tool and the actual value calculated above are graphically displayed. Control line displayed shows the variation of the response ($\sigma, 2\sigma, 3\sigma$). The overall results are shown in Fig. 5.

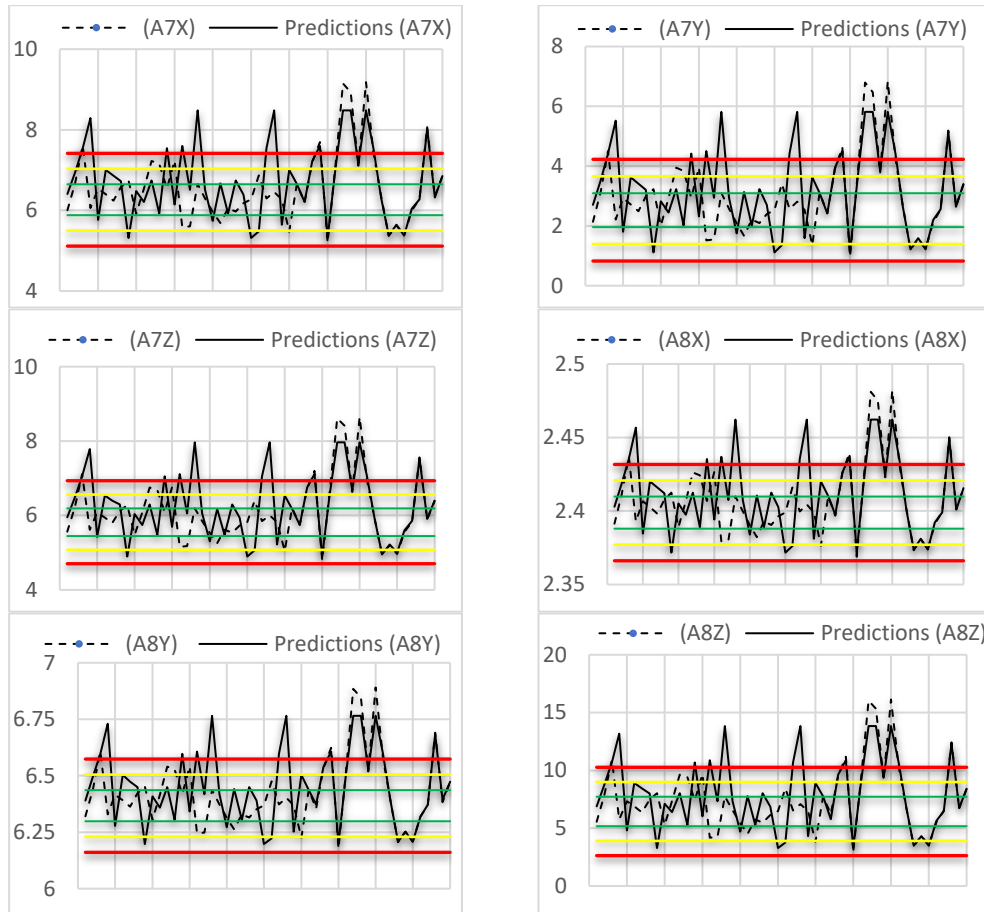


Fig. 5. Global results.

It can be seen that reference and validation models exhibit similar behaviours, although there are differences due to sample size and that random sampling does not perfectly fit the actual behaviour of the structure, although adapts considerably.

4.4 Conclusions

The enormous technological advances made in recent decades in the fields of instrumentation and detection have made SHM a mature area in terms of monitoring, conveying the challenge to the correct management of the large amounts of data available and the creation of smart structures.

The main advantages of using SHM-based methodologies lie in their versatility and flexibility to adapt to any system or structure, regardless of the level of complexity. In addition, the increasing availability of data makes it easier to build robust statistical models that make these algorithms more reliable.

The study demonstrates the usefulness of managing available historical data derived from periodic monitoring processes to monitor the evolution of the behaviour of certain critical elements in structures.

5 Acknowledgements

The work presented here has received funding from Horizon 2020, the EU's Framework Programme for Research and Innovation, under grant agreement number 690660 (Project: RAGTIME), and also under grant agreement number 769373 (Project: FORESEE).

6 References

1. Zilong Wei, Alfredo Núñez, Xiubo Liu, Rolf Dollevoet, Zili Li, Multi-criteria evaluation of wheel/rail degradation at railway crossings, *Tribology International*, Volume 144, Article number 106107 (2020)
2. David García-Sánchez, Statistical control and regression models. A practical approach in bridge control, PhD Thesis, University of Cantabria. (2016)
3. Joel P. Conte, Rodrigo Astroza, Gianmario Benzoni, Glauco Feltrin, Kenneth J. Loh: *Experimental Vibration Analysis for Civil Structures*. (2018)
4. Javier Sánchez Haro, Development of theory on impacts. Simplified method of calculation of impacts in structures, PhD Thesis, University of Cantabria. (2017)
5. Zhou Jianting, Yang Jianxi, Wu Diankun: A method for Analysis Linear Correlation for Multi-Sensor of Bridge Monitoring System. (2009)
6. Xiaojun Weia, Justin Russell, Stana Živanović, J. Toby Mottram, Measured dynamic properties for FRP footbridges and their critical comparison against structures made of conventional construction materials, *Composite Structures* Volume 223, Article number 110956 (2019).
7. L. Ellam, M. Girolami, G. A. Pavliotis, A. Wilson, Stochastic modelling of urban Structure, *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* Volume 474, Issue 2213, Article number 20170700 (2018)
8. Gascon, M., Kumar, N., Ghosh, R, Predicting Power Plant Equipment Life Using Machine Learning, *Journal of Energy Resources Technology, Transactions of the ASME*, Volume 142, Issue 7, Article number 072101 (2020)

ANEXO III: BIBLIOGRAFÍA

- [1] **David García Sánchez.** *Control Estadístico y modelos de Regresión lineal. Una forma práctica de control de puentes.* Universidad de Cantabria. (2016)
- [2] **Ana Fdez-Navamuel del Olmo.** *Desarrollo de una herramienta de detección de daños para la toma de decisión en gestión de puentes.* Universidad de Cantabria. (2018)
- [3] **Carlo Rainieri, Giovanni Fabbrocino.** *Operational Modal Analysis of Civil Engineering Structures.* (2014)
- [4] **Joel P. Conte, Rodrigo Astroza, Gianmario Benzoni, Glauco Feltrin, Kenneth J. Loh.** *Experimental Vibration Analysis for Civil Structures.* (2018)
- [5] **Javier Sánchez Haro.** *Desarrollo de teoría sobre impactos. Método simplificado de cálculo de impactos en estructuras.* Universidad de Cantabria. (2017)
- [6] **Zhou Jianting, Yang Jianxi, Wu Diankun.** *A method for Analysis Linear Correlation for Multi-Sensor of Bridge Monitoring System.* (2009)
- [7] **Breiman, L.** *Arcing The Edge* (June 1997)
- [8] **Friedman, J. H.** Greedy Function Approximation: A Gradient Boosting Machine. (1999)
- [9] **Friedman, J. H.** Stochastic Gradient Boosting. (1999)
- [10] **Mason, L.; Baxter, J.; Bartlett, P. L.; Frean, Marcus.** *Boosting Algorithms as Gradient Descent.* S.A. Solla and T.K. Leen and K. Müller, ed. *Advances in Neural Information Processing Systems.* (1999)
- [11] **Mason, L.; Baxter, J.; Bartlett, P. L.; Frean, Marcus.** *Boosting Algorithms as Gradient Descent in Function Space.* (2018).
- [12] **Peña Sánchez de Rivera, Daniel.** *Deducción de distribuciones: el método de Montecarlo.* (2001).
- [13] **David García, Ignacio Piñero, Sergio Pérez, Aratz García.** *The Value of Structural Health Monitoring for the reliable Bridge Management.* (2017)
- [14] **Breiman, L. & Friedman, J.** *Estimating optimal transformations in multiple regression and correlation.* (1985)

[15] *Scikit Machine Learning in Python.*

[16] **Shai Shalev-Shwartz, Shai Ben-David.** *Understanding Machine Learning, From Theory to Algorithms.* (2014)

[17] **Manuel Hidalgo Martinez.** *Teoría de Vibraciones*

[18] **Ramon Pallas Areny.** *Sensores y Acondicionadores De Señal (4ª ED.)*

INDICE DE FIGURAS

Figura 2.1. Etapas de un SHM.	15
Figura 2.2. Representación gráfica de la energía cinética en función del coef. de masas en diversos casos de impacto.	31
Figura 4.1. Etapas de elaboración de un SHM	44
Figura 4.2. Ejemplo de aparato de dilatación de vía (bretelle).	45
Figura 4.3. Descripción de la estructura (puente de Bouleta, Bilbao).	46
Figura 4.4. Esquema de colocación de acelerómetros y fases de medición.	47
Figura 4.5. Ejemplos de medidas no válidas.	49
Figura 4.6. Extracto de Limpieza de acelerómetros.	50
Figura 4.7: Cálculo de picos y tramos de estudio (verde)	51
Figura 4.8. Relaciones de Acelerómetros.	55
Figura 4.9. Grados de correlación sobre A7	56
Figura 4.10. Grados de correlación sobre A8	56
Figura 4.11. Inputs-Outputs de los Modelos A7 y A8.	59
Figura 4.12. Comparación de resultados del Acelerómetro 7X	63
Figura 4.13. Comparación de resultados del Acelerómetro 7Y	64
Figura 4.14. Comparación de resultados del Acelerómetro 7Z.	64
Figura 4.15. Comparación de resultados del Acelerómetro 8X	65
Figura 4.16. Comparación de resultados del Acelerómetro 8Y	65
Figura 4.17. Comparación de resultados del Acelerómetro 8Z.	66
Figura 4.18. Alarma en A7X.	68
Figura 4.19. Alarma en A7Y.	68
Figura 4.20. Alarma en A7Z.	69
Figura 4.21. Alarma en A8X.	69
Figura 4.22. Alarma en A8Y	70
Figura 4.23. Alarma en A8Z	70

INDICE DE TABLAS

Tabla 2.1. Tipos de sensores	26
Tabla 4.1. Frecuencias obtenidas y valores de Temperatura y Humedad.	52
Tabla 4.2. Correlaciones	57
Tabla 4.3. Correlaciones Optimas	58

Tabla 4.4. Resumen de correlaciones	59
Tabla 4.5. Valores de entrenamiento de la herramienta	61
Tabla 4.6. Datos de validación de la herramienta.....	62

