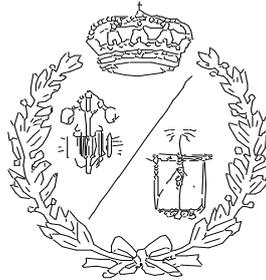


ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA



Proyecto Fin de Máster

**DESARROLLO DE UNA HERRAMIENTA DE
DETECCIÓN DE DAÑOS PARA LA TOMA
DE DECISIÓN EN GESTIÓN DE PUENTES**

**(Damage detection tool development for
decision making in Bridge Management)**

Para acceder al Título de

**MÁSTER UNIVERSITARIO EN
INGENIERIA INDUSTRIAL**

Autor: Ana Fdez-Navamuel del Olmo

julio - 2018

RESUMEN

En las últimas décadas, los Sistemas de Monitorización Estructural (*SHM*) han ido ganando importancia en nuestra sociedad. Su objetivo fundamental es proporcionar información cuantitativa y dar soporte a los ingenieros para profundizar en la valoración del comportamiento de las estructuras bajo las condiciones de servicio reales, de forma que puedan optimizar los programas de mantenimiento y evitar la ocurrencia de fallos estructurales graves, más aún cuando aparecen en el horizonte de la gestión de las infraestructuras conceptos como el de resiliencia.

Los grandes avances tecnológicos experimentados en el ámbito de la instrumentación han permitido desarrollar nuevas técnicas de inspección cada vez más sofisticadas que proporcionan grandes cantidades de datos en muy poco tiempo. Este fenómeno se ha convertido en una prometedora fuente de información en cuanto al control de la integridad estructural, imponiendo un nuevo reto sobre cómo gestionar estos volúmenes de datos para transformarlos en una herramienta de conocimiento al servicio de los propietarios y gestores de las estructuras.

Con este trabajo, centrado en el post-procesado, se pretende explotar la capacidad informativa de los datos procedentes de la instrumentación en un puente mediante el desarrollo de una herramienta de detección de anomalías estructurales en el mismo.

El procedimiento se integra dentro de las metodologías de *SHM* basadas en datos, que recurren al "*Machine Learning*" para desarrollar algoritmos de reconocimiento de patrones estadísticos que permitan clasificar los distintos estados de la estructura sin necesidad de crear modelos de cálculo que introduzcan nuevas incertidumbres a la hora de entender las mediciones reales, aprovechando exclusivamente la información aportada por la instrumentación.

Para ello, se emplean varias técnicas de procesamiento de datos, como el Análisis de Componentes Principales (*PCA*), que proporciona un indicador de la presencia de daño en la estructura. Mediante análisis estadísticos se describirá un modelo representativo del

estado de referencia que permita resolver un problema de clasificación entre los dos posibles estados de la estructura: dañado y no dañado.

Finalmente, una vez diseñada la herramienta, se formulará su integración en el sistema de *SHM* con el objetivo de valorar cuantitativamente la evolución del comportamiento de la estructura prácticamente en tiempo real al reactivarse el sistema de instrumentación.

Palabras clave: Monitorización Estructural (*SHM*), detección de daños, aprendizaje automático, reconocimiento de patrones estadísticos, Análisis de Componentes Principales, modelo de referencia comportamiento anómalo, Sistema de Gestión de Puentes, toma de decisión, análisis de datos.

ABSTRACT

In the last decades, monitoring systems have gained increasing importance in our society. Their main objective is to provide quantitative information and support for the engineers to take the right decisions and deepen on structures performance under real service conditions, in order to optimize the maintenance programs and avoid severe failures, even more when new concepts such as resilience are appearing in the context of infrastructures management.

The great technological improvements experienced in the instrumentation field allowed the development of new sophisticated inspection techniques that provide large amounts of data in a short time. This “Big Data” phenomenon has become a promising source of information on structural integrity control, introducing a new challenge on how to manage these data volumes to turn them into a knowledge tool to help owners and structure managers.

This work, focussed on the post-processing stage, aims to exploit the informative ability of data coming from a bridge instrumentation system by means of the development of a structural novelty detection tool for condition assessment of the bridge.

The procedure is integrated within the data-based *SHM* methodologies, which develop statistical pattern recognition algorithms through “Machine Learning” techniques to solve a classification problem among the different possible states of the structure, with the main advantage of not requiring the definition of computation models that may induce new uncertainties and difficulties to understand the real measurements, taking advantage exclusively of the information provided by instrumentation.

To achieve this objective, several data processing techniques are used, such as Principal Component Analysis, which provides a numerical indicator for abnormal structural behaviour detection. By means of statistical analysis, a representative model for the reference or healthy state of the structure is described, allowing to solve a simple classification problem between two possible states: damaged and undamaged.

Finally, once the tool has been designed, its integration and implementation onto the whole *SHM* system is addressed, providing an accurate evaluation of the structural behaviour in practically real time after the instrumentation system has been reactivated for acquiring new data.

Key words: Structural Health Monitoring (SHM), damage detection, Machine Learning, Statistical Pattern Recognition, Principal Component Analysis, baseline model, abnormal behaviour, Bridge Management System, decision making, data analysis.

AGRADECIMIENTOS

Me gustaría mostrar mi agradecimiento a todas las personas que, directa o indirectamente, han participado en este proyecto.

Quiero dar las gracias particularmente a Daniel Alvear Portilla, codirector de este Proyecto, por apoyarme y por todos sus consejos.

A David García Sánchez, por su todo su apoyo, su predisposición y su ayuda; por enseñarme tanto y tratarme tan bien, y en definitiva por haber hecho posible este proyecto.

También quiero dar las gracias de forma especial a Javier Torres Ruiz, por ser quien me descubrió el mundo de las estructuras y las estructuras del mundo, y por enseñarme, entre otras muchas cosas, que *“el nacimiento de un conjunto estructural, resultado de un proceso creador, fusión de técnica con arte, de ingenio con estudio, de imaginación con sensibilidad, escapa del puro dominio de la lógica para entrar en las secretas fronteras de la inspiración”* (Eduardo Torroja).

Por último, quiero agradecer a mi familia y amigos su paciencia y todo su apoyo durante la elaboración de este proyecto.

ÍNDICE

RESUMEN.....	III
ABSTRACT	V
AGRADECIMIENTOS.....	VII
CAPÍTULO 1. INTRODUCCIÓN	1
1.1. CONTEXTUALIZACIÓN	1
1.2. MOTIVACIÓN	3
1.3. ALCANCE Y OBJETIVOS	4
1.4. ESQUEMA DEL TRABAJO	5
CAPÍTULO 2. MONITORIZACIÓN DE LA SALUD	
ESTRUCTURAL	7
2.1. INTRODUCCIÓN	7
2.2. DEFINICIÓN DE DAÑO	9
2.3. AXIOMAS DE LA SHM	12
2.4. ESTRATEGIAS DE MONITORIZACIÓN	15
2.5. MOTIVACIÓN PARA EL DESARROLLO DE LA SHM ...	17
2.6. EL ROL EMERGENTE DE LA SHM PARA LA GESTIÓN	19

CAPÍTULO 3. METODOLOGÍA..... 21

3.1. INTRODUCCIÓN 21

3.2. DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE SHM..... 22

3.2.1. Evaluación Operacional..... 22

3.2.2. Adquisición y transmisión de datos 24

3.2.3. Tratamiento de datos..... 28

3.2.4. Extracción de parámetros característicos 29

3.2.5. Desarrollo de modelos estadísticos de evaluación 30

3.3. POSTPROCESO: DETECCIÓN DE DAÑOS MEDIANTE APRENDIZAJE NO SUPERVISADO 32

3.3.1. Introducción..... 32

3.3.2. Definición del modelo estadístico de referencia 33

3.3.3. Establecimiento del límite de confianza 43

3.3.4. Validación de la herramienta 45

3.3.5. Implementación en el sistema de SHM 49

CAPÍTULO 4. CASO DE ESTUDIO..... 52

4.1. INTRODUCCIÓN 52

4.2. EVALUACIÓN OPERACIONAL..... 53

4.2.1. Descripción de la estructura instrumentada 53

4.2.2. Motivación de la instrumentación 54

4.3. INSTRUMENTACIÓN Y PROCESAMIENTO	55
4.3.1. Descripción del sistema de instrumentación	55
4.3.2. Adquisición y transmisión de datos	59
4.3.3. Procesamiento de datos	59
4.4. POSTPROCESO	62
4.4.1. Introducción.....	62
4.4.2. Creación del modelo de referencia.....	62
4.4.3. Establecimiento del nivel de confianza.....	69
4.4.4. Validación de la herramienta	71
4.4.5. Implementación de la herramienta en el sistema de SHM ..	76

CAPÍTULO 5. CONCLUSIONES Y NUEVAS LÍNEAS DE INVESTIGACIÓN

81

5.1. INTRODUCCIÓN	81
5.2. CONCLUSIONES.....	82
5.2.1. Conclusiones sobre la instrumentación	82
5.2.2. Conclusiones sobre las metodologías basadas en datos	83
5.2.3. Conclusiones sobre el postproceso de los datos.....	84
5.2.4. Conclusiones sobre la herramienta de detección de daños	85
5.3. NUEVAS LÍNEAS DE INVESTIGACIÓN	87
5.3.1. Líneas de investigación sobre la instrumentación.....	87
5.3.2. Líneas de investigación sobre el sistema de SHM	88
5.3.3. Líneas de investigación en el ámbito de la gestión	90

ANEXO I. DISEÑO COMPUTACIONAL DE LA HERRAMIENTA	91
SCRIPT 1: CONFIGURACIÓN DE LA HERRAMIENTA.....	92
SCRIPT 2: FUNCIÓN DE EVALUACIÓN.....	96
SCRIPT 3: FUNCIÓN DE ACTUALIZACIÓN.....	97
SCRIPT 4: CONSOLA DE TRABAJO.....	99
ANEXO II. DIAGRAMAS DE FLUJO	101
LISTA DE FIGURAS.....	105
BIBLIOGRAFÍA.....	108
LIBROS.....	108
TESIS DOCTORALES Y PROYECTOS ACADÉMICOS	109
ARTÍCULOS CIENTÍFICOS Y OTROS DOCUMENTOS.....	110

“Estamos siendo testigos de un cambio en la relación tradicional entre realidad y representación. Ya no evolucionamos del modelo a la realidad, sino del modelo al modelo, al tiempo que reconocemos que, en realidad, ambos modelos son reales. En consecuencia, podemos trabajar de un modo muy productivo con la realidad experimentada como un conglomerado de modelos. Más que considerar el modelo y la realidad como modalidades polarizadas, ahora funcionan al mismo Nivel. Los modelos han pasado a ser coproductores de la realidad”

Olafur Eliasson

CAPÍTULO 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, hospitales o colegios, infraestructuras 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.

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 inteligente que proporcionen una visión cuantitativa y precisa sobre la condición real de las estructuras. Esto se consigue mediante un proceso de determinación, seguimiento y evaluación 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 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 para convertirlos en fuentes de información constante sobre el estado estructural.

La Monitorización Estructural (*SHM*) se puede definir de forma simplificada como el proceso de implementación de estrategias de detección y caracterización de daños en infraestructuras ingenieriles. Este proceso requiere el control de unos indicadores de comportamiento a partir de datos visualizados o medidos y simulaciones analíticas combinadas con la experiencia ingenieril.

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).

A día de hoy, la mayoría 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 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.

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 no requieren la elaboración de modelos analíticos o numéricos que se ajusten a las mediciones realizadas in situ, sino que trabajan 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. 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.

1.2. MOTIVACIÓN

Los grandes avances tecnológicos realizados tanto en el ámbito de la instrumentación como en el de las tecnologías de la comunicación, han generado una nueva concepción de las estructuras como potenciales fuentes de información constante que ha permitido desarrollar ampliamente los sistemas de *SHM* para proporcionar una evaluación objetiva de la situación real de las estructuras.

En muchos casos, este contexto ha hecho que la *SHM* se convierta en una disciplina orientada más a la explotación de las posibilidades tecnológicas disponibles que a unos objetivos claramente definidos, convirtiendo estos sistemas en un coste adicional en lugar de una herramienta de optimización de la gestión. Solo si se dispone de una gran eficiencia en la gestión de los grandes volúmenes de datos proporcionados por la instrumentación se logrará garantizar la confianza en la toma de decisiones, resultando en una mayor eficiencia operacional, reducción de costes y minimización de riesgos.

Por ello, la motivación de este proyecto surge de la necesidad de aportar la máxima utilidad a los datos procedentes de la instrumentación de las estructuras como fase fundamental para la implementación óptima de los sistemas de *SHM*.

Por otro lado, este trabajo supone una continuación del trabajo realizado por David García Sánchez en su Tesis Doctoral, donde se abordaron todos los temas concernientes al desarrollo e implementación de un sistema de instrumentación, así como el procesamiento posterior de los datos para analizar mediante Gráficos de Control el estado de la estructura. Además, esta Tesis planteó un enfoque predictivo a través de la creación de unos modelos basados en la inferencia estadística mediante bandas de predicción, que

permitían detectar desviaciones del comportamiento normal de la estructura mediante la valoración de las correlaciones entre las mediciones de los sensores.

El presente proyecto se centra en la continuación de una de las líneas de investigación propuestas por dicha Tesis, que parte de la matriz de correlaciones obtenida mediante la estimación de todos los modelos predictivos de regresión lineal, como referencia para el desarrollo de nuevos estudios de detección de daños a nivel de estructura.

En resumen, se busca aportar un enfoque global en la evaluación de la integridad estructural, que permita identificar el estado de funcionamiento en base a un único parámetro unificador de la información de todos los sensores para poder facilitar la toma de decisiones a nivel de red, contribuyendo así a la cohesión de las distintas etapas del enfoque multi-escala de la gestión de estructuras (sensor, estructura y red).

1.3. ALCANCE Y OBJETIVOS

Este trabajo pretende aportar una visión global de la utilidad de los datos procedentes de la instrumentación como potencial fuente de información para el desarrollo de herramientas que permitan detectar anomalías en el comportamiento estructural, y actualizar su estado de forma continuada, 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 puentes críticos pertenecientes a una red de infraestructuras civiles, mediante las técnicas de *SHM* y partiendo del trabajo realizado por David García Sánchez en su Tesis, que supuso un nuevo enfoque para 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 resolver un problema de clasificación entre los dos posibles estados de la estructura: dañado y no dañado.

Para ello, se aplicarán estas técnicas a un caso práctico real a partir de los datos de instrumentación de un puente proporcionados por el autor de la Tesis de la que parte este proyecto.

Como resultado final, se pretende proporcionar una herramienta para los Sistemas de Gestión de Puentes que derive en un uso más eficiente de los recursos económicos disponibles y una mejor organización de las labores de mantenimiento.

Los principales objetivos del proyecto son:

- I. Justificar la importancia de la gestión y aprovechamiento de las grandes cantidades de datos proporcionados por la instrumentación en el ámbito de la Monitorización Estructural.
- II. Introducir el concepto de monitorización de la integridad estructural (*SHM*) y su importancia en la gestión de puentes a nivel económico y de seguridad.
- III. Proporcionar una base de conocimiento sobre la implementación eficiente de los sistemas de Monitorización Estructural y su aplicabilidad en la detección de daños mediante modelos estadísticos.
- IV. Proponer una herramienta de detección de anomalías mediante un algoritmo de reconocimiento de patrones a partir de los datos procedentes de la instrumentación de un puente.
- V. Aportar un enfoque integrador en la valoración del estado de las estructuras que unifique la información proporcionada por todos los sensores para agilizar la toma de decisiones.

1.4. ESQUEMA DEL TRABAJO

En el capítulo 2 se presenta una introducción al concepto de la monitorización de la salud estructural, considerando los aspectos económicos y de seguridad que la convierten en un instrumento necesario en los sistemas de gestión de puentes actuales.

El capítulo 3 se centra en el diseño e integración eficiente de un sistema de *SHM* basado en técnicas de reconocimiento de patrones estadísticos.

La aplicabilidad de la metodología de *SHM* con reconocimiento de patrones estadísticos se estudiará en el capítulo 4 mediante el empleo de sus conceptos principales en un caso de estudio práctico: a partir de conjuntos de datos registrados durante el comportamiento normal de un puente real sometido a condiciones ambientales variables durante un año, se elaborará una herramienta capaz de identificar la presencia de anomalías en el sistema estructural.

Finalmente, en el capítulo 5 se presentan las conclusiones y se proponen las líneas de investigación a futuro que permitan seguir avanzando en este ámbito hacia un dominio completo del control estructural.

CAPÍTULO 2

MONITORIZACIÓN DE LA SALUD ESTRUCTURAL

2.1. 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 y mecánica, ya que constituye una herramienta muy potente para asegurar la integridad y la seguridad de los sistemas estructurales.

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, cargar 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.

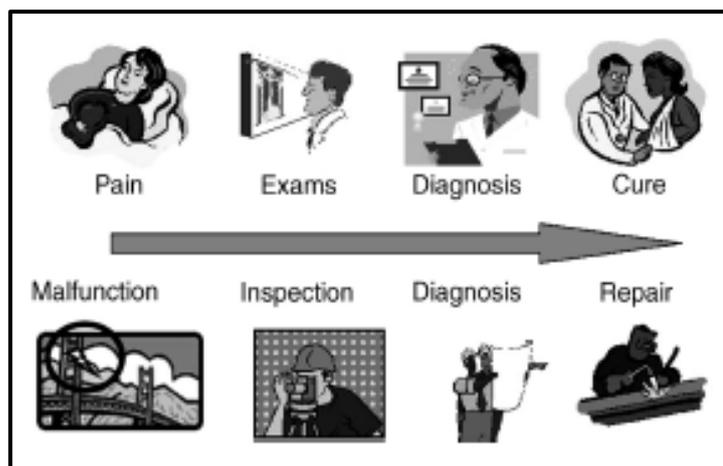


Figura 1 Analogía entre el control médico y el control estructural

El diagnóstico de daños en los sistemas estructurales implica principalmente la identificación del daño, junto con una posterior caracterización de su localización, tipo y severidad. Un sistema robusto de *SHM* estará compuesto de las siguientes etapas:

- | | |
|---|-----------------|
| • Nivel 1: ¿Existe un daño presente en la estructura? | DETECCIÓN |
| • Nivel 2: ¿Dónde se encuentra ese daño? | LOCALIZACIÓN |
| • Nivel 3: ¿Cuál es el tipo de daño detectado? | CARACTERIZACIÓN |
| • Nivel 4: ¿Cuál es la gravedad del daño? | EXTENSIÓN |
| • Nivel 5: ¿Cuál es la vida remanente prevista? | PRONÓSTICO |

La idea que reside detrás de esta jerarquía 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 supondrá 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 efectiva 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 proceder a 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.

2.2. DEFINICIÓN 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, como se muestra en la figura 2, 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.

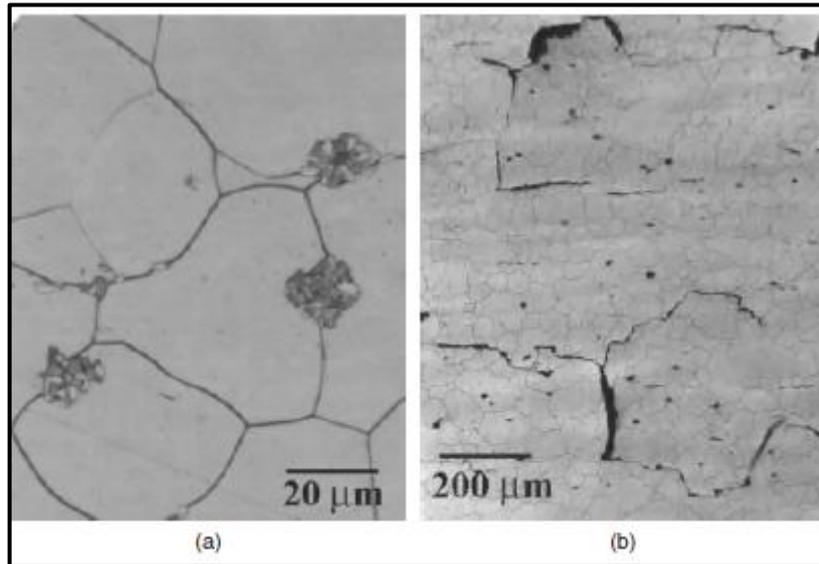


Figura 2 (a) Inclusiones en los bordes de grano en U-6Nb. (b) Propagación de grieta a lo largo de las líneas de inclusión tras una carga de choque

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.

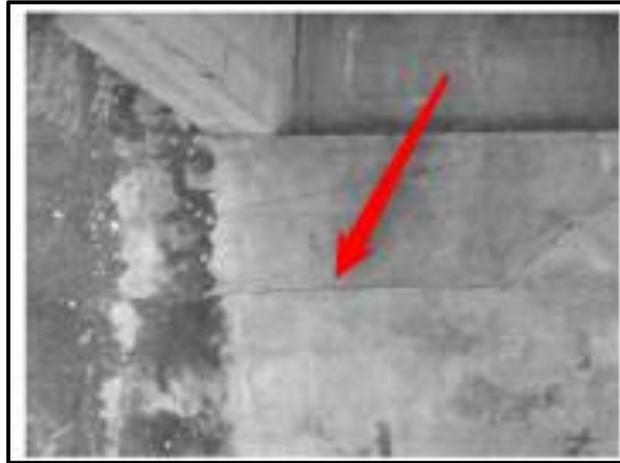


Figura 3 Grieta horizontal en mitad de estribo

- 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.

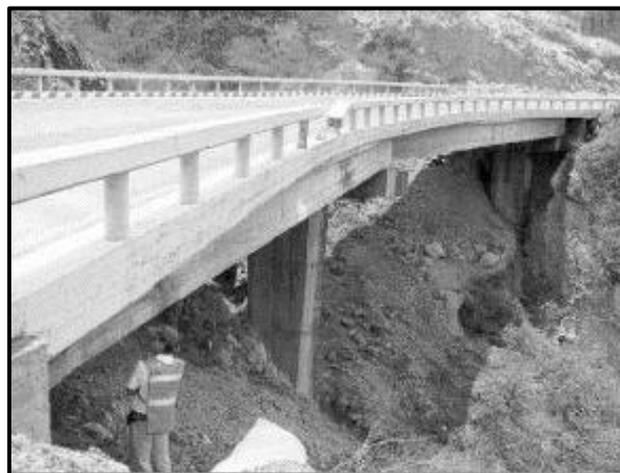


Figura 4 Deslizamiento de talud del puente

- 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.



Figura 5 Corrosión y deterioro de apoyo balancín de acero



Figura 6 Reducción de la sección de viga por corrosión e impacto

- 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)

2.3. AXIOMAS DE LA 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 al 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.

2.4. ESTRATEGIAS DE MONITORIZACIÓN

Cada proyecto de monitorización o seguimiento presentará sus particularidades y, aunque es posible estandarizar la mayor parte de los elementos de un sistema de *SHM*, cada aplicación será única en el modo en que estos estén combinados en última instancia. Es posible clasificar los distintos tipos de monitorización según algunas categorías: escala de la instrumentación, tipo de parámetros de medición, periodicidad del registro, tipo de respuesta, forma de recolección de datos, etc. A continuación, se desglosa en detalle esta clasificación:

Nivel de escala

- **Escala local:** el comportamiento se analiza atendiendo a las propiedades locales de los materiales de la construcción. Las mediciones más típicas son distribuciones de esfuerzos locales o penetración de químicos en el hormigón.
- **Escala de miembro:** en este caso se observa cierto número de elementos seleccionados como críticos para estudiar su comportamiento global, realizando mediciones como la carga en un cable pretensado.
- **Escala global:** la estructura se estudia desde el punto de vista de su comportamiento conjunto y su respuesta.
- **Escala de red:** se trata de monitorizar varias estructuras pertenecientes a un sistema estructural, permitiendo al propietario tomar decisiones fundamentadas a nivel de sistema, sobre la asignación prioritaria de fondos o la planificación de reparaciones en las diversas estructuras que se encuentren en el mismo tramo de autovía, por ejemplo.

Parámetros de medición

- **Mecánicos:** esfuerzos, desplazamientos, curvatura, rotaciones, etc.
- **Físicos:** temperatura del material, humedad, etc.
- **Químicos:** PH, nivel de cloro o de sulfato, etc.
- **Ambientales:** temperatura del aire, humedad, radiación solar, viento, etc.
- **Acciones:** cargas de vehículos, fuerzas, etc.

Periodicidad

- **Periódico:** mediciones manuales a intervalos predeterminados, como por ejemplo una vez cada tres meses.
- **Semi-continuo:** mediciones automáticas sobre intervalos de tiempo predefinidos, como una medición por hora, durante una semana, cada tres meses.
- **Continuo:** mediciones automáticas permanentes, por ejemplo, cada hora.

Tipo de respuesta

- **Periódica:** medición de parámetros de variación lenta
- **Dinámica:** medición de vibraciones u otras respuestas dinámicas

Sistema de transmisión de datos

- **Ninguno:** los sensores se instalan, pero no toman medidas y el sistema se activa únicamente cuando es necesario
- **Manual:** las mediciones son llevadas a cabo por un operario in situ.
- **Off – line:** el sistema registra los datos automáticamente y se descargan periódicamente a través de una línea de comunicación o manualmente.
- **On – line:** los datos están constantemente disponibles online.
- **Tiempo real:** los datos son registrados online y analizados inmediatamente para proporcionar una retroalimentación inmediata a los usuarios y propietarios.

Método de interpretación de datos:

- **Basado en modelo físico:** necesita modelos físicos que representen con la mayor precisión posible la estructura de análisis y con los que se relacionarán los cambios en los datos medidos sobre la estructura real.
- **Basado en datos:** recurre a algoritmos de reconocimiento de patrones estadísticos para asignar a las mediciones reales un determinado estado.

Todos estos tipos de monitorización pueden combinarse según las necesidades específicas de cada puente que se quiera controlar, siempre y cuando se lleve a cabo un diseño riguroso del mismo para adaptarlo correctamente.

2.5. MOTIVACIÓN PARA EL DESARROLLO DE LA 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.

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 la misma 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.

2.6. EL ROL EMERGENTE DE LA SHM PARA LA GESTIÓN

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 las mismas. 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.

CAPÍTULO 3

METODOLOGÍA

3.1. INTRODUCCIÓN

La *SHM* es el proceso de evaluar y valorar la integridad y seguridad de un sistema estructural en base a los datos recogidos de manera autónoma y continua por una red de sensores.

En el siguiente apartado se realiza una presentación de todas las etapas involucradas en la implementación de un sistema de *SHM*, desde la toma de datos in situ hasta el procesamiento último para obtener los modelos estadísticos de análisis y diagnóstico. La siguiente figura muestra un diagrama de flujo del proceso de diseño de un sistema de *SHM*:

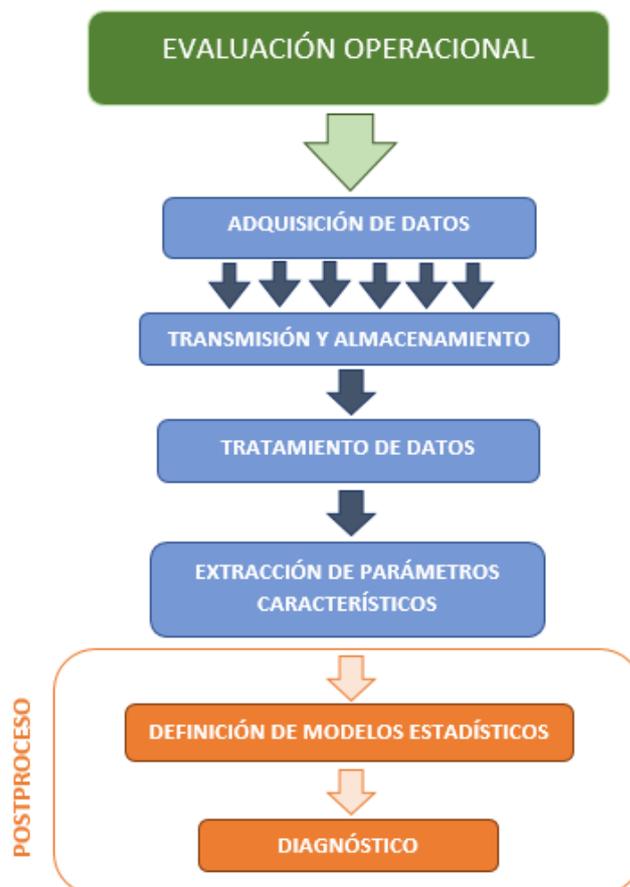


Figura 7 Organigrama del desarrollo de un sistema de Monitorización Estructural

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.

3.2. DISEÑO E IMPLEMENTACIÓN DE UN 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.

3.2.1. Evaluación Operacional

Identificación de las estructuras que necesitan seguimiento

Antes de considerar la implantación de un sistema de *SHM*, es importante evidenciar si una estructura determinada podría sacar partido de él. A continuación, se presenta una lista de situaciones en las que se considera interesante y beneficioso emplear un sistema de *SHM*:

- Nuevas estructuras que incluyan aspectos innovadores en su diseño, procedimiento de construcción o materiales empleados.
- Nuevas estructuras con riesgos o incertidumbres asociadas poco usuales, incluyendo condiciones geológicas hostiles, riesgo sísmico, riesgos de carácter meteorológico, ambientes de trabajo agresivos, vulnerabilidad durante la construcción, calidad de los materiales y mano de obra.
- Estructuras que puedan considerarse críticas a nivel de red, debido al fuerte impacto que pudiera tener en los usuarios y sobre el resto de estructuras de la red en caso de fallo o deficiencia de funcionamiento.
- Estructuras nuevas o existentes que sean representativas de una población mayor de estructuras idénticas o similares. En este caso, la mayor parte de la información obtenida de un subconjunto estructural puede ser extrapolada a la población completa.
- Estructuras existentes con deficiencias conocidas a partir de inspecciones visuales.
- Estructuras pendientes de acciones de reemplazo o renovación. En este caso, la *SHM* se emplearía para evaluar la necesidad real de esas actuaciones y optimizar su diseño y ejecución.

Análisis de riesgo y respuesta estructural

El diseñador del sistema de *SHM*, los ingenieros de diseño y los ingenieros encargados de la evaluación estructural, así como el propietario de la estructura, deben identificar los riesgos asociados a la misma y su probabilidad de ocurrencia. El análisis de riesgo generará una lista de posibles sucesos y degradaciones que pueden afectar de algún modo a la estructura.

Algunos ejemplos de riesgos e incertidumbres son la corrosión, la pérdida del pretensado, deslizamientos, hundimiento de la cimentación, terremotos, sobrecargas no autorizadas, impactos, escasez de precisión en los modelos de elementos finitos, material de construcción de baja calidad o ejecución inadecuada.

La gravedad y la probabilidad de cada riesgo podrá clasificarse usando un procedimiento de análisis de riesgos para jerarquizarlos adecuadamente. En este punto, algunos riesgos podrán ser descartados debido a su escaso impacto o probabilidad y como resultado se tendrá una lista de los principales riesgos a considerar por el sistema de *SHM*.

Para cada uno de los riesgos seleccionados es necesario asociar una o más respuestas que podrían observarse de forma directa o indirecta, en caso de ocurrir. Por ejemplo, la corrosión producirá un cambio en la composición química de los materiales, pero también una reducción de la sección. Si esto no se considera, la imprecisión de los modelos asociados podría provocar diferencias inadmisibles entre la respuesta de la estructura y la del modelo.

Por ello, es interesante cuantificar las respuestas y seleccionar los sensores que tengan las especificaciones apropiadas, de manera que sea posible determinar qué respuestas son fácil y eficientemente observables mediante inspecciones visuales periódicas y cuáles necesitarían el uso de instrumentación. También es interesante identificar las localizaciones donde es más posible que ocurran estas respuestas (zonas y elementos críticos).

El resultado de este paso es una lista de respuestas que necesitan ser detectadas y medidas, su localización y su amplitud estimada.

3.2.2. Adquisición y transmisión de datos

Esta es una de las fases más importantes del proceso de *SHM* ya que tiene un impacto muy significativo en la capacidad del sistema y constituye la fuente de información para las fases posteriores.

Los sistemas de transmisión y almacenamiento de datos para *SHM* suelen estar formados por los siguientes componentes:

Sensores y actuadores

Son los dispositivos especializados que se instalarán en contacto directo con los diferentes elementos y/o materiales de la estructura, cuya función es la medición directa de alguna característica: temperatura, inclinación, deformación. En el caso de los sistemas activos, los actuadores se encargan de introducir una excitación conocida en la estructura, para monitorear su respuesta.

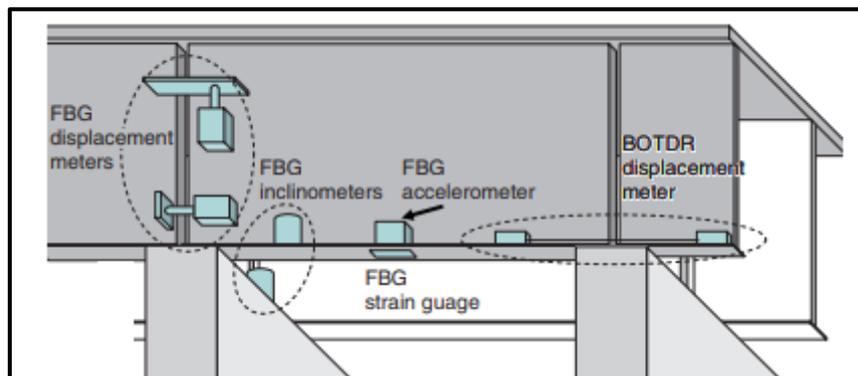


Figura 8 Ejemplo de emplazamiento de sensores

Estos dispositivos son capaces de convertir las variaciones de una magnitud física – lectura directa de una determinada variable o señal de entrada: deformación, inclinación, tensión, ... - en variaciones de una magnitud eléctrica, a través de una señal de salida que será función de la variable medida por medio de convertidores analógico-digitales. Dependiendo del tipo de daño que se pretenda identificar y de la tipología de sensores que se instale, se podrán alcanzar mejores relaciones entre las mediciones y la presencia de daño.

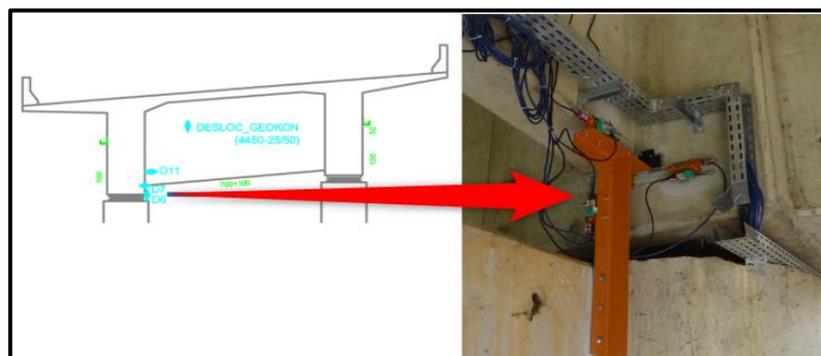


Figura 9 Galga de esfuerzo de hilo vibratorio

En la actualidad, existe una amplia gama de sensores, desde los basados en fibra óptica, hasta los piezoeléctricos y dieléctricos, las galgas de esfuerzo o incluso sensores de láser. Suele ser recomendable incluir sensores de varias tecnologías para incrementar la redundancia del sistema y poder complementar las mediciones para garantizar una mayor fiabilidad de los datos.

Sistema de Adquisición de Datos (SAD)

Es el elemento encargado de la recepción de las medidas realizadas por los sensores por medio de un software informático que las procesa, almacena y transmite. Está formado básicamente por un ordenador y por el cableado que lo conecta con los sensores y debe poseer una fuente de alimentación continua (esto se logrará mediante la incorporación de un convertidor). Los datos podrán ser almacenados manualmente, semi-automáticamente o automáticamente, en el sitio o remotamente, periódica o continuamente, estática o dinámicamente.

Actualmente, la transmisión inalámbrica se está convirtiendo en una técnica prometedora que podría impactar muy fuertemente en el ámbito de la Monitorización Estructural. Este tipo de monitorización surgió para superar los problemas de los sistemas convencionales con transmisión por cable, ya que la comunicación inalámbrica elimina muchos problemas como el exceso de cables, el deterioro de la señal en largas distancias de transmisión y el daño que pueda sufrir la instrumentación o el equipamiento como resultado del entorno de trabajo. Además, las redes inalámbricas ofrecen un entorno de computación distribuido, que hace posible extender las capacidades de análisis en los nodos de medición permitiendo un diagnóstico multi-escalonado y la toma de decisiones fundamentada.

Programa de control del sistema

Se trata de un software específicamente diseñado para el procesamiento, el análisis y la presentación de los datos.

Los sistemas de sensores y de almacenamiento de datos necesitarán estar protegidos tanto de las condiciones ambientales como de la propia interferencia humana. Dependiendo de las condiciones ambientales a las que tenga que enfrentarse el sistema, los sistemas de sensores, adquisición de datos y almacenamiento podrán ser alquilados de forma periódica con la intención de reducir su deterioro y su reemplazamiento. También existe la posibilidad de que ocurran fallos de suministro eléctrico, en cuyo caso será necesaria una fuente secundaria o la reactivación automática el sistema.

Las unidades de adquisición y almacenamiento necesitarán disponer de suficiente memoria RAM y espacio en disco para poder acumular todos los datos medidos.

En la siguiente figura se resume el proceso completo de adquisición y transmisión de los datos hasta su procesamiento digital.

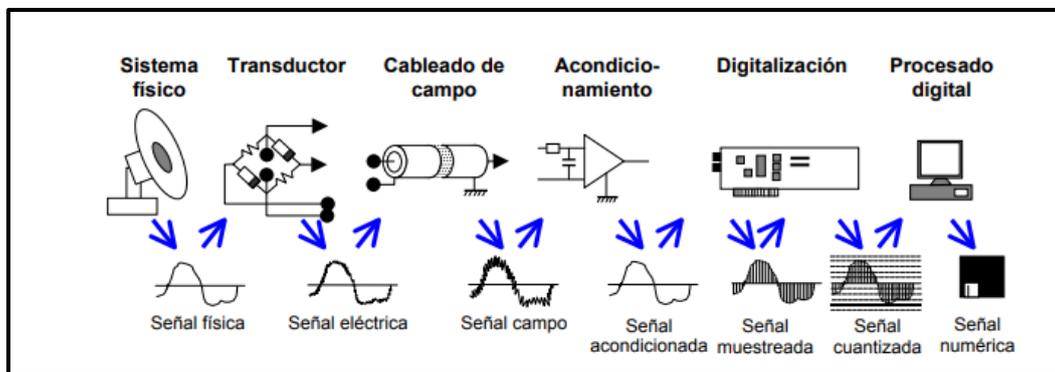


Figura 10 Esquema general del procesamiento de señales

Esta fase se concluye con un ensayo de validez in situ, y como resultado se dispondrá de un documento de diseño que incluirá una lista de sensores y demás aparatos, los planos de instalación y de cableado, el procedimiento e itinerario de instalación y el presupuesto.

3.2.3. Tratamiento de 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.
- **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 el 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.

3.2.4. 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.

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.

3.2.5. Desarrollo de modelos estadísticos de evaluación

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.

3.3. POSTPROCESO: DETECCIÓN DE DAÑOS MEDIANTE APRENDIZAJE NO SUPERVISADO

3.3.1. Introducción

La detección de daños estructurales, que se corresponde con el primer nivel de conocimiento en el ámbito de la identificación de daños mediante la *SHM*, se puede considerar como un problema simple de clasificación entre dos posibles estados: el estado de referencia (H_0), y el estado correspondiente a cualquier situación fuera de la normalidad (H_1).

Debido a la complejidad y los costes asociados a la obtención de datos correspondientes a las posibles situaciones de riesgo o deterioros que puedan sufrir las estructuras, las técnicas de detección de daños presentan la ventaja de emplear algoritmos de aprendizaje no supervisado, y en muchos casos la información que

proporcionan es suficiente para efectuar una buena valoración del estado estructural y una adecuada definición de las tácticas de mantenimiento a implementar.

La resolución de estos problemas se realiza mediante técnicas de reconocimiento de patrones, que básicamente consisten en comparar la respuesta estructural medida respecto del modelo de referencia, para poder realizar un diagnóstico del estado en el que se encuentra la estructura.

Para poder poner en práctica esta metodología, es necesario seguir unos pasos fundamentales en la construcción de la herramienta:

- Definir el modelo estadístico del estado de referencia
- Establecer un nivel de confianza para el diagnóstico
- Validar la herramienta mediante datos de estado conocido
- Implementar la herramienta en el sistema de *SHM*

En los siguientes apartados se realiza una descripción en profundidad de estas cuatro fases necesarias para una correcta implementación de la herramienta de detección de fallos estructurales, presentando las técnicas que se emplearon en el caso de estudio realizado.

3.3.2. Definición del modelo estadístico de referencia

El primer paso para configurar la herramienta de detección de daños debe centrarse en la elaboración de un modelo de referencia que permita la posterior comparación. Este modelo se formará a partir de los datos extraídos del proceso de monitorización, que habrán sido analizados para garantizar que se corresponden con una situación de funcionamiento normal de la estructura.

Análisis de Componentes Principales

Para poder crear un modelo estadístico eficaz, es necesario realizar una caracterización estadística de los datos. Esta caracterización presenta el problema de que, para aproximar adecuadamente una distribución de probabilidad, el tamaño de la muestra debe crecer exponencialmente con respecto a la dimensión del espacio muestral, lo que significa que a medida que crecen las dimensiones de la muestra, serán necesarios más datos para describir de forma correcta su distribución. En resumen, a medida que aumentan las dimensiones del espacio paramétrico, serán necesarios más datos para describir la distribución, y esto podría imponer graves limitaciones prácticas en los algoritmos de detección de fallos.

Debe aclararse la diferencia entre la extracción de parámetros característicos y la reducción de datos: la extracción de parámetros característicos consiste en la identificación de propiedades sensibles al daño presentes en las señales de respuesta medidas por los sensores, proceso, eso sí, que puede resultar en una reducción colateral de los datos; por su parte, la reducción de datos resulta de un tratamiento posterior aplicado sobre los parámetros característicos seleccionados para facilitar el trabajo de los algoritmos de detección de fallos.

El **Análisis de Componentes Principales** es una técnica estadística multivariable que consiste en proyectar los datos originales en un espacio de menores dimensiones por medio de una transformación lineal que conserve la sensibilidad al daño de los parámetros originales. Entre sus ventajas destacan la capacidad de analizar y eliminar relaciones entre variables, de minimizar la redundancia entre ellas, así como de obtener una descripción exhaustiva de la estructura existente tras los datos originales.

En el ámbito de la SHM, el análisis de componentes principales permite calcular un índice de daño para cada elemento de la muestra de referencia, cuya distribución de probabilidad conforma el modelo estadístico de referencia.

Los componentes principales se obtienen resolviendo el problema de valores propios sobre la matriz de covarianzas de las variables originales, que consiste en proyectar los datos, por medio de una transformación lineal, sobre un nuevo conjunto de coordenadas cartesianas (ortogonales entre sí), dando lugar a un espacio de menores dimensiones. Cada componente principal contiene un porcentaje descendente de la varianza total presente en los datos originales, de manera que el porcentaje acumulado por todos los componentes será el 100% de la varianza original.

El resultado final son una serie de componentes con una elevada varianza e independientes entre sí (no correlacionados), de modo que se eliminan las variables redundantes y la información se simplifica.

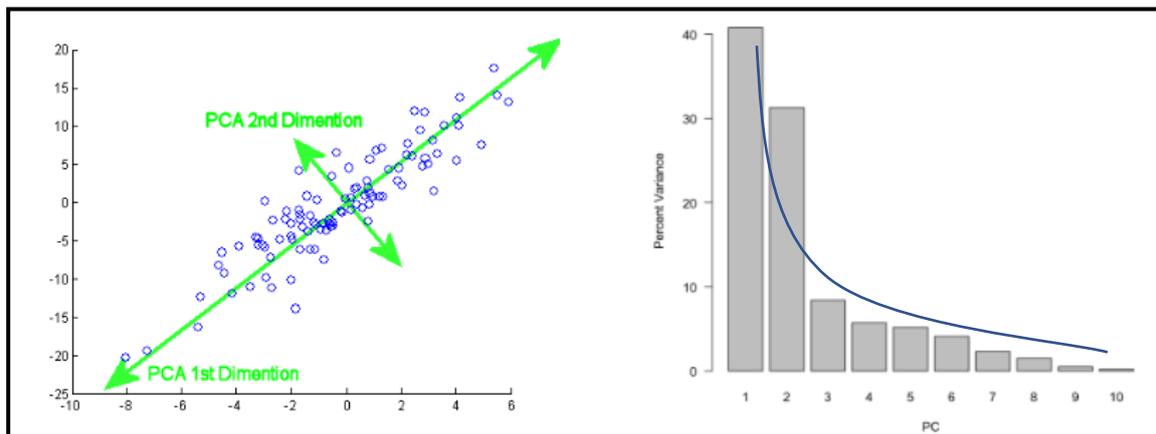


Figura 11 Análisis de Componentes Principales

A continuación, se describe detalladamente el procedimiento matemático de obtención de los componentes principales para el posterior cálculo de un índice de daño denominado θ^2 .

Se dispone de una serie de mediciones realizadas por m sensores (variables) en diferentes instantes de tiempo (n), de modo que cada medición es un elemento muestral del conjunto de datos de trabajo. Por lo tanto, se puede construir una matriz de datos original, que adoptará la siguiente forma:

$$X = \begin{pmatrix} \begin{matrix} x_{11} \\ \dots \\ x_{i1} \\ \dots \\ x_{n1} \end{matrix} & \begin{matrix} x_{12} \\ \dots \\ x_{i2} \\ \dots \\ x_{n2} \end{matrix} & \dots & x_{1j} & \dots & x_{1m} \\ & & \dots & \dots & \dots & \dots \\ & & & x_{ij} & \dots & x_{im} \\ & & & \dots & \dots & \dots \\ & & & x_{nj} & \dots & x_{nm} \end{pmatrix} \quad (1)$$

Esta matriz $n \times m$ contiene la información recogida por m sensores durante n mediciones experimentales. Cada vector fila representa las mediciones de todos los sensores en un instante específico, y cada vector columna se corresponde con todas las mediciones de un único sensor.

Debido a que las variables físicas medidas por los sensores pueden tener diferentes magnitudes, el siguiente paso a llevar a cabo es una normalización de los datos, de manera que cada vector columna se convierta en una muestra de media cero y desviación estándar unitaria.

Existen multitud de técnicas para normalizar los datos, aunque una de las más conocidas es la conocida como “auto escalado”, que consiste en re-escalar cada variable convirtiéndola en un vector de media cero y varianza unitaria. La modificación matemática a realizar es la siguiente:

$$\mu_j = \frac{1}{n} \sum_{i=1}^n x_{ij}, \quad (2)$$

$$\sigma_j^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \mu_j)^2, \quad (3)$$

$$\bar{x}_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (4)$$

Donde μ_j y σ_j^2 son la media y la varianza respectivamente, del sensor j , y los elementos \bar{x}_{ij} formarán la nueva matriz normalizada, que será la que se utilizará en los cálculos sucesivos.

Una vez que se tiene la matriz de referencia normalizada, se realiza el proceso de transformación lineal a través de la matriz de direcciones principales P :

$$T = X \cdot P \quad (5)$$

Para conseguir el objetivo de minimizar la redundancia entre variables, se buscará una matriz de transformación P tal que la covarianza de la nueva matriz transformada T sea diagonal, lo cual implica que:

$$C_T = \frac{1}{n-1} T^T \cdot T \quad (6)$$

Sustituyendo (5) en la expresión anterior, se tendrá:

$$C_T = \frac{1}{n-1} P^T \cdot X^T \cdot X \cdot P = P^T \cdot C_X \cdot P \quad (7)$$

Puesto que la matriz C_X es una matriz simétrica, tendrá m valores reales λ_j y m vectores propios ortonormales, denominados \mathbf{p}_j , que forman la base del nuevo espacio de m dimensiones. Por tanto, la matriz de transformación P es aquella que contiene a los vectores propios en sus columnas:

$$P = (\mathbf{p}_1 | \mathbf{p}_2 | \dots | \mathbf{p}_j | \dots | \mathbf{p}_m) \quad (8)$$

Con esta matriz, se cumple la siguiente propiedad:

$$C_X \cdot P = P \cdot \Lambda \quad (9)$$

donde $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m)$. Sustituyendo (9) en la expresión (7), la condición impuesta en (6) se cumplirá con:

$$C_T = P^T \cdot P \cdot \Lambda = \Lambda \quad (10)$$

De forma más detallada, cada vector columna de la matriz original transformada T puede expresarse como:

$$t_j = X \cdot \mathbf{p}_j \quad (11)$$

De este modo, los vectores fila de la matriz de referencia transformada T pasan a estar no correlacionados y sus varianzas correspondientes están dadas por los valores propios de la matriz de covarianza C_X de la muestra de datos original. Típicamente, los vectores propios que constituyen la matriz de transformación P se disponen en orden descendente según el nivel de varianza justificada y conforman los denominados Componentes Principales del conjunto de datos.

El vector propio con el mayor valor propio representa el patrón más importante de los datos originales, aportando la mayor cantidad de información.

Geoméricamente, el vector columna j de la matriz transformada T es la proyección de los datos originales sobre la dirección del vector p_j . De manera intuitiva, la matriz T proporciona una nueva representación de los datos como si fueran tomados a través de unos sensores virtuales en un espacio no físico, donde las correspondientes variables asociadas a ellos no están correlacionadas y presentan la mayor variabilidad de los datos y por tanto un mayor potencial para la detección de daños. [A.4]

La reducción dimensional se obtiene de la selección de aquellos valores propios que mejor justifiquen la variabilidad presente en los datos. Debido a que los vectores propios o direcciones principales está ordenados de acuerdo a la cantidad de información que aportan, es posible reducir de forma simple la dimensionalidad del conjunto de datos seleccionando solo algunos componentes principales. De este modo, la matriz reducida P , contendrá únicamente los r vectores propios seleccionados:

$$P = (p_1 | p_2 | \dots | p_r) \quad (12)$$

Y la matriz transformada se volverá a calcular del mismo modo, con la nueva matriz de transformación simplificada:

$$T = X \cdot P \quad (13)$$

Muchas veces, la matriz transformada mediante una selección de componentes principales no resulta suficiente para alcanzar una detección de daños estructurales robusta y deben calcularse unos índices de daño a partir de esta información, que sirvan para crear un modelo estadístico de referencia más potente.

En este contexto, hay que definir unos umbrales que ayuden a valorar si la variabilidad de los datos es admisible o no. El PCA puede usarse para detectar comportamientos anómalos de la estructura por medio de dos indicadores estadísticos elementales: el estadístico T^2 y el estadístico Q . El primero de ellos se encarga de analizar la matriz transformada T .

Por su parte, el segundo se basa en analizar la parte residual de la matriz transformada, que sería la proyección de los datos sobre los componentes principales no seleccionados. Ambas técnicas suelen acogerse a la consideración de que los datos originales siguen aproximadamente una distribución normal multivariada. [A.18]

Estadístico T^2

Este indicador, también denominado como distancia de Hotelling, es una generalización del estadístico “t de student”, que se emplea en los procesos de verificación de hipótesis. Considerando x_i como el vector fila m que representa las mediciones de todos los sensores en el experimento o instante i , t_{si} será el vector fila r (fila dentro de la matriz T) correspondiente a la proyección de la medición x_i en el nuevo espacio, siendo: $t_{si} = x_i P$

El estadístico T^2 del elemento muestral “ i ” se calcula como:

$$T_i^2 = \sum_{j=1}^r \frac{t_{sij}^2}{\lambda_j} = t_{si} \Lambda^{-1} t_{si}^T = \mathbf{x}_i P \Lambda^{-1} P^T \mathbf{x}_i^T \quad (14)$$

Este estadístico únicamente detecta la variación en el subespacio de los primeros r componentes principales. Es decir, que es una forma de medición de la variación de cada elemento de la muestra en el modelo de PCA.

Estadístico Q

Este índice hace referencia a los cambios inducidos por eventos que no se explican mediante los principales componentes del modelo de PCA. Es una medición de la diferencia o residuo entre la muestra original y su proyección en el modelo. El indicador para el vector de mediciones x_i se define como:

$$Q_i = \mathbf{x}_i (I - P \cdot P^T) \mathbf{x}_i^T \quad (15)$$

donde I es una matriz identidad ajustada en tamaño a las nuevas dimensiones del modelo P .

La información sobre el comportamiento estructural puede obtenerse directamente representando los componentes principales seleccionados (más relevantes). Cuando exista un cambio en el sistema, los valores propios cambiarán, y se podrá detectar la alteración. Sin embargo, esta información está directamente presente en el estadístico T^2 , ya que se calcula usando esas magnitudes.

Complementariamente, el estadístico Q proporciona información adicional que no está incluida en la representación de componentes, ya que está vinculado a aquellas variaciones que no están siendo consideradas por el modelo. De este modo, los modelos de los indicadores T^2 y Q son evaluaciones de hipótesis que distinguen claramente aquellas mediciones anómalas, mientras que la comparación de valores propios aporta información cualitativa.

Normalmente, el estadístico Q es mucho más sensible a las variaciones que el estadístico T^2 , debido a que toma valores mucho más pequeños y cualquier ligero cambio en las características del sistema podrá ser detectable. Por su parte, el indicador T^2 , presenta una gran varianza, y por lo tanto necesitará mayores cambios en las características del sistema para poder detectar un daño.

Para poder tener en cuenta la información proporcionada por los dos indicadores, se suele recurrir a un indicador global o combinado, que es la suma de ambos y permite disponer de una magnitud única que caracterice el estado de la estructura sin perder información de ninguno de los indicadores. Este indicador se designa como: $\theta = T^2 + Q$.

Para conseguir un indicador más robusto ante posibles variaciones derivadas de las condiciones ambientales u operativas, se propone el cálculo de un índice combinado mediante la suma ponderada de los indicadores T^2 y Q , donde se concederá menor peso al indicador Q por ser más sensible a las variaciones y por tanto más susceptible de generar falsas alarmas. El indicador combinado se plantearía como: $\theta' = \alpha \cdot T^2 + \beta \cdot Q$

donde α y β son los parámetros de ponderación que tomarán valores entre 0 y 1.

Función de Distribución de kernel

Una vez se han calculado los índices de daño para cada una de las mediciones de la muestra de referencia, se puede estimar su modelo estadístico mediante la estimación de la función de distribución de probabilidad que mejor se ajuste. Esto se puede abordar desde dos perspectivas diferentes: por estimación paramétrica o no paramétrica.

En la estimación paramétrica, la distribución estadística de los datos se asume de antemano, y los parámetros correspondientes que caracterizan la distribución se estiman a partir de los datos. Por ejemplo, puede asumirse que los datos presentan una distribución Gaussiana, cuyos parámetros estadísticos, media y varianza, deben ser estimados a partir de los conjuntos de datos disponibles. Sin embargo, no hay una garantía total de que la distribución seleccionada capture adecuadamente las características o propiedades de los datos. Cuando se emplee este tipo de enfoque paramétrico, es necesario realizar una comprobación del nivel de adecuación de la distribución estimada y los datos reales.

Por su parte, la estimación no paramétrica no impone restricciones innecesarias sobre los datos de estudio, sino que permite que la distribución se defina a partir de ellos. Ese enfoque resulta de gran utilidad cuando no se conoce la distribución de la que proceden los datos, o en caso de disponer de varias distribuciones diferentes en un mismo problema. Algunos ejemplos de esta tipología de modelado estadístico son el histograma y el estimador de kernel.

La función de densidad de kernel es una estimación de la distribución de los datos similar al histograma, pero con la ventaja de proporcionar un modelo continuo sobre el que calcular probabilidades. La idea fundamental que reside en este enfoque es que cada punto de la muestra que se quiere caracterizar estadísticamente contribuye en la misma proporción a la estimación final, de tal forma que la densidad se acumulará en aquellas regiones donde haya más datos. En términos matemáticos, la expresión básica de la función kernel para datos multivariados es:

$$\hat{p}(\{x\}) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{\{x\} - \{x\}_i}{h}\right) \quad (16)$$

donde $\{x\}_i$ es el dato de la muestra “i”, N es el tamaño de la muestra empleada, y h es el parámetro de suavizado que controla la anchura de la ventana de cálculo; $\hat{p}(\{x\})$ es la estimación de la densidad real $p(\{x\})$. La función de kernel $K(\{x\})$ puede ser cualquier función localizada que satisfaga las dos restricciones siguientes:

$$K(\{x\}) > 0 \quad (17)$$

$$\int_{-\infty}^{\infty} K(\{x\}) d\{x\} = 1 \quad (18)$$

La función kernel más comúnmente utilizada es la que se obtiene como una superposición de múltiples funciones gaussianas:

$$K(\{x\}) = \frac{1}{(2\pi)^{h/2}} \exp\left(-\frac{1}{2} \|\{x\}\|^2\right) \quad (19)$$

donde h es la dimensión espacial de los datos.

Una vez que se ha definido la función de estimación, cualquier densidad de probabilidad de una nueva medición puede ser evaluada de forma simple.

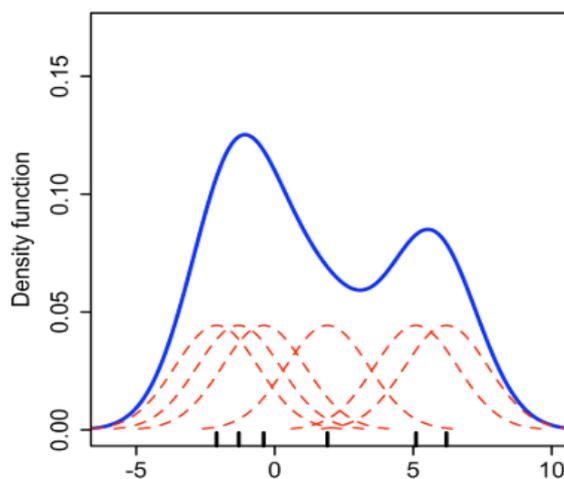


Figura 12 Composición de una función kernel gaussiana

La calidad de la estimación depende principalmente de dos factores. El primer factor es el tamaño de la muestra, y el segundo factor es la magnitud del parámetro h.

Si h es demasiado pequeño, la distribución de probabilidad estimada contendrá excesiva información innecesaria localizada en ciertas zonas. Si h es demasiado grande, la estimación estará sobre-suavizada, sin información de su distribución real, provocando un posible aumento del número de falsos negativos en el diagnóstico. Existen algunas técnicas para estimar el parámetro h , en función de las características de los datos. En el caso de la distribución Gaussiana, el valor óptimo de h puede estimarse como:

$$h_{opt} = \sigma \cdot \sqrt[5]{\frac{4}{3 \cdot N}} \quad (20)$$

donde σ es la varianza de la población que puede aproximarse a la varianza de la muestra, y N es el tamaño de la muestra.

En el caso de trabajar con datos multimodales, el estimador óptimo de la función Gaussiana puede ser demasiado elevado, puesto que la función normal es multimodal, y esto podría llevar a una pérdida de información considerable sobre la distribución real. En este caso, el estimador óptimo de h se calcularía como:

$$h_{optM} = \frac{0.9 \cdot \hat{\sigma}}{\sqrt[5]{N}} \quad (21)$$

donde $\hat{\sigma} = \min\left(s, \frac{R}{1.34}\right)$, siendo R el rango intercuartil ($Q3 - Q1$)

3.3.3. Establecimiento del límite de confianza

Las técnicas de detección de anomalías mediante el reconocimiento de patrones estadísticos se basan en la comparación de los nuevos datos registrados con el modelo de referencia asociado a la condición normal de funcionamiento de la estructura. De esta manera, se inferirá la presencia de daño cuando una nueva medición presente un valor excesivamente alejado de la media de la distribución del estado no dañado o si se encuentra en una región de muy baja densidad de probabilidad. De forma general se puede asumir que los datos correspondientes a la condición normal se encontrarán localizados en la zona de alta probabilidad, y aquellos con carácter atípico ocurrirán en las regiones de menor probabilidad.

En el caso concreto de los índices de daño, se debe asumir una distribución unilateral, es decir: con una sola cola para la definición del límite de aceptación. Esto se debe a que los índices de daño más pequeños, que presentarán también probabilidades bajas, no pueden considerarse como posibles casos de anomalía o daño, sino que se corresponderán con aquellas situaciones particulares en que los datos prácticamente no presentan variabilidad y por tanto el índice de daño es altamente reducido.

Por lo tanto, la validez de la herramienta de detección no depende únicamente de una adecuada caracterización de la distribución de los datos (modelo estadístico), sino que también será necesaria una adecuada definición del límite de aceptación entre estados. Este nivel de aceptación o límite para la detección de daño se determina en base a un cierto nivel de confianza que dependerá de la seguridad que se pretenda tener en los diagnósticos.

Mediante el establecimiento de un nivel de incertidumbre (α), se define la confianza que se tendrá a la hora de realizar afirmaciones sobre los diagnósticos y fundamentar la toma de decisiones: $NC = (1 - \alpha) \cdot 100\%$

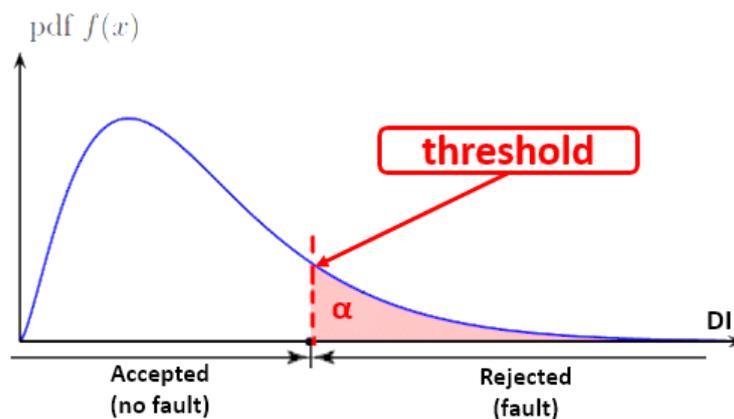


Figura 13 Delimitación de estado sobre el modelo de referencia

Para poder establecer de forma adecuada el nivel de confianza, es necesario introducir los distintos tipos de error en el diagnóstico: tipo I y tipo II. El error de tipo I, también conocido como error falso positivo, consiste en indicar la presencia de daño cuando la estructura se encuentra realmente en buen estado. Por su parte, los errores de tipo II o errores falso negativo se producen cuando la herramienta no detecta un daño presente.

Para una toma de decisiones adecuada en el campo de la *SHM*, se necesita encontrar un compromiso entre estos dos tipos de error, puesto que no es posible reducirlos simultáneamente.

Por lo tanto, el usuario deberá decidir cuál de los dos errores tiene prioridad según la aplicación y el caso concreto de estudio. Por ejemplo, en el caso de una planta de energía nuclear, será mucho más importante minimizar los errores falsos negativo ya que un defecto no detectado puede originar un desastre catastrófico. Por otro lado, un exceso de alarmas falsas positivas puede dar lugar a una desactivación innecesaria del dispositivo que corresponda, como por ejemplo un detector de humo.

En el ámbito de la monitorización de la salud estructural, es muy común establecer un nivel de incertidumbre del 5% ($\alpha=0.05$), siendo el nivel de confianza:

$$NC = (1 - \alpha) \cdot 100 = 95\% \quad (22)$$

Esto quiere decir que cada vez que la herramienta de detección de fallos realice un diagnóstico sobre el estado de la estructura, se tendrá un 95% de seguridad en él, asumiendo una pequeña probabilidad de que la valoración se incorpore incorrecta. Puesto que nos encontramos en el ámbito del aprendizaje no supervisado, este nivel de confianza nos aportará información de cara a los falsos positivos, es decir, en aquellos casos en los que la herramienta detecte un fallo que no existe.

3.3.4. Validación de la 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.

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.

En este caso, se buscará generar una serie de datos correspondientes al estado no dañado. Puesto que se dispone de una muestra del estado de referencia, se puede emplear la estimación de densidad de kernel para aproximar el comportamiento estadístico de estos datos, y obtener nuevas mediciones “ficticias” que sigan ese comportamiento.

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, 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.

Para poder obtener la muestra de validación, se debe efectuar un análisis correlacional de la muestra de datos original que ha llevado a la elaboración del modelo de referencia. Cuando dos variables presentan una relación lineal, el diagrama de dispersión correspondiente tiende a estar agrupado alrededor de la recta de mínimos cuadrados, que es aquella que ajusta los datos de la mejor forma. Esta recta viene definida por una ecuación, y los datos se ajustarán a ella con cierta desviación, denominada residuo. La variable independiente o explicativa se encarga de explicar o definir a la variable dependiente a través de la ecuación de regresión lineal. El valor del residuo representa la diferencia entre el valor observado en los datos y el pronosticado por la recta de mínimos cuadrados.

La recta de mínimos cuadrados que relaciona las variables genéricas x e y se obtiene mediante el siguiente procedimiento matemático:

$$\hat{y} = b_0 + b_1 \cdot x \quad (23)$$

$$b_1 = \frac{\sum xy - \frac{(\sum x)(\sum y)}{n}}{(\sum x^2) - \frac{(\sum x)^2}{n}} \quad (24)$$

$$b_0 = \bar{y} - b_1 \bar{x} \quad (25)$$

donde n es el tamaño de la muestra de las dos variables, x e y ; \hat{y} es el valor que toma la variable dependiente o respuesta según la recta de mínimos cuadrados; y b_0 y b_1 son los parámetros que definen la ecuación.

Se puede decir que la desviación del valor que toma realmente la variable dependiente y el valor asignado por la predicción lineal, se deben a la presencia de un residuo o error aleatorio, de tal forma que, para cada medición de la muestra:

$$y_i = \hat{y}_i + e_i = f(x) + e_i \quad (26)$$

El residuo o error aleatorio contiene el efecto que tienen todas las variables distintas de x sobre la variable dependiente y puede expresarse estadísticamente de forma aproximada mediante una distribución normal de media cero y desviación estándar σ .

De este modo, si se dispone de una muestra de datos de la variable x obtenida mediante muestreo aleatorio de su distribución de probabilidad, se podrán obtener las muestras de los demás sensores mediante la recta de regresión tomando un valor aleatorio del residuo según su distribución: $e_i \approx N(0, \sigma^2)$

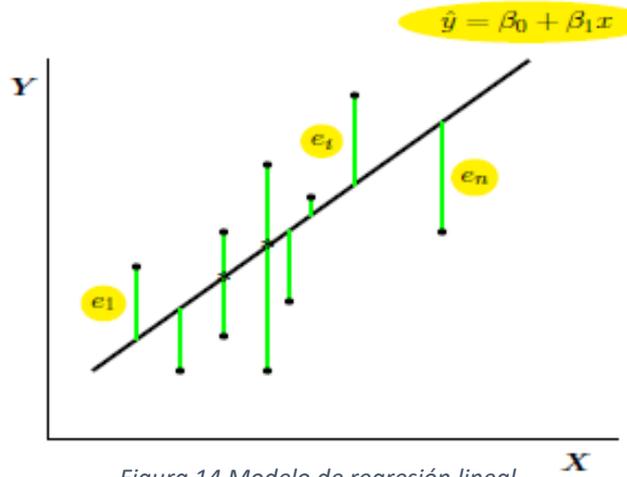


Figura 14 Modelo de regresión lineal

Creación del modelo de validación

Una vez obtenida la muestra, el procedimiento a seguir es el mismo que el planteado para la obtención del modelo de referencia, normalizando los datos y calculando los índices de fallo mediante la proyección sobre las componentes principales de referencia para poder comparar la información.

$$\bar{x}_{vij} = \frac{x_{vij} - \mu_j}{\sigma_j} \quad (27)$$

$$T_i^2 = \mathbf{x}_{vi} P \Lambda^{-1} P^T \mathbf{x}_{vi}^T \quad (28)$$

$$Q_i = \mathbf{x}_{vi} (I - P \cdot P^T) \mathbf{x}_{vi}^T \quad (29)$$

$$\theta_i = T_i^2 + Q_i \quad (30)$$

donde x_{vij} se corresponde con la medición original “i-ésima” del sensor “j” en la muestra de validación, y \mathbf{x}_{vi} es el vector normalizado de todas las mediciones (multi-sensor) del instante “i”.

Finalmente, el comportamiento estadístico se obtiene también a través de la función de densidad de kernel. Ambos modelos deben quedar prácticamente superpuestos debido a que proceden del mismo estado (no dañado) de la estructura.

Si el modelo de validación no coincide a simple vista con el modelo de referencia, se considerará que la herramienta está mal calibrada, y deberán revisarse todos los pasos realizados para la definición del modelo de referencia y el establecimiento del límite de aceptación, desde el análisis y procesamiento de los datos brutos registrados por los sensores por si existiera algún error.

Para evaluar la herramienta de forma más exhaustiva, se puede calcular un índice o ratio de falsas alarmas que cuantifique la cantidad de diagnósticos falsos positivos que realiza la herramienta con los datos de validación. La expresión para calcular el ratio es la siguiente:

$$FAR (False Alarm Ratio) = \frac{\text{number of false alarms}}{\text{validation sample size}} \cdot 100 (\%) \quad (31)$$

Se puede decir que, para un tamaño suficiente de muestra, si el indicador de falsas alarmas es inferior al nivel de incertidumbre asumido para la herramienta, esta estará funcionando de forma robusta. Además, como la generación de datos no es costosa, pueden generarse tantas muestras de validación como se desee.

3.3.5. Implementación en el sistema de SHM

Una vez se ha definido y comprobado la herramienta, es posible incorporarla al sistema completo de *SHM* para controlar y valorar el estado real de la estructura en tiempo real. Para ello, el primer paso consistirá en reactivar el sistema de monitorización durante un período de inspección para registrar nuevas mediciones de los parámetros de interés, que serán directamente sometidos al cálculo los índices de fallo mediante una operación sencilla:

$$T_{new}^2 = \mathbf{x}_{new}(P\Lambda^{-1}P^T)\mathbf{x}_{new}^T \quad (32)$$

$$Q_{new} = \mathbf{x}_{new}(I - P \cdot P^T)\mathbf{x}_{new}^T \quad (33)$$

$$\theta_{new} = T_{new}^2 + Q_{new} \quad (34)$$

donde \mathbf{x}_{new} es el vector fila normalizado con las mediciones de todos los sensores en cierto instante actual tras la reactivación del sistema.

Los nuevos índices de daño θ_{new} se someterán al algoritmo de reconocimiento de patrones para identificar a qué estado de la estructura pertenecen, según el diagrama de flujo siguiente:

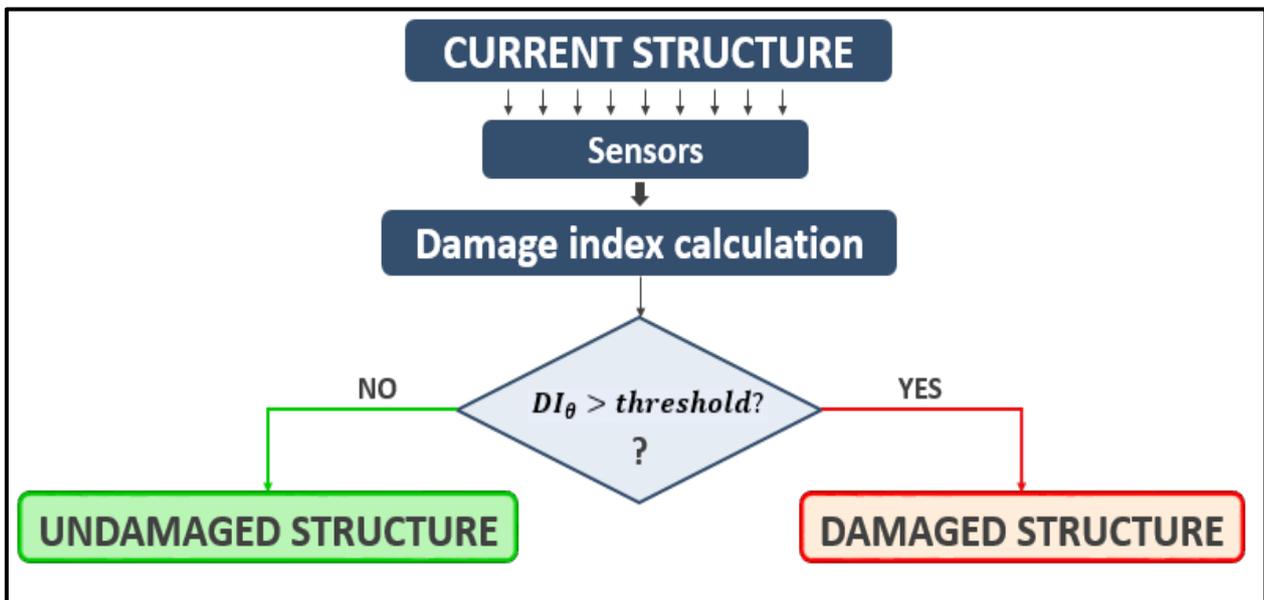


Figura 15 Implementación de la herramienta de detección de daños en el sistema de SHM

Mediante este procedimiento se podrán ir evaluando las nuevas mediciones tomadas por los sensores en el estado actual desconocido de la estructura, y detectar la presencia de tendencias en los índices de daño o valores extremadamente altos que podrían suponer la presencia de daños.

La idea es tomar datos durante un período de un mes para tener información suficiente que permita dar soporte a las inspecciones visuales actuales para la toma de decisiones sobre el estado de las estructuras y su necesidad real de ser atendidas.

También podría reactivarse el sistema de instrumentación durante el proceso de revisión in situ (un día), y emplear esos datos para reforzar la información proporcionada por las inspecciones visuales. Además, este sistema permitiría analizar cuantitativamente el estado de la estructura después de alguna catástrofe natural, como inundaciones o terremotos, dando una idea de cómo se ha visto afectada por el fenómeno.

Otro aspecto importante de su capacidad de realizar diagnósticos prácticamente en tiempo real reside en la posibilidad de tomar decisiones rápidas sobre la necesidad de cesar el servicio de una estructura, en caso de existir riesgos para la seguridad de los usuarios.

En resumen, la combinación de las técnicas de inspección visual, junto con los algoritmos de detección de daños permite elaborar un sistema de alarma de robustez controlada ante situaciones críticas en el funcionamiento de las estructuras, además de optimizar las estrategias de mantenimiento y asignación de recursos para las labores de reparación y sustitución.

CAPÍTULO 4

CASO DE ESTUDIO

4.1. INTRODUCCIÓN

El presente proyecto surge con la idea de incorporar los algoritmos de Machine Learning en un sistema de *SHM* para crear una herramienta sencilla de detección de anomalías en tiempo real a partir de los datos almacenados en labores de monitorización que están siendo desaprovechados. Para ello, y como se describió en el tercer capítulo 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.

Para poder abordar el problema de forma práctica, se propuso la implementación del sistema en una estructura real instrumentada de la que se tenían datos procedentes de un período de monitorización. Las fases de instrumentación, adquisición y procesamiento de los datos fueron el objeto de desarrollo de la Tesis Doctoral de David García Sánchez, y constituyeron el punto de partida para la elaboración de la herramienta de detección de fallos.

De forma simplificada, el siguiente diagrama muestra las fases principales para la implementación eficiente de un sistema de *SHM*, que ya se describieron en detalle en el tercer capítulo de este trabajo.



En este capítulo se describen todas las etapas implicadas en el desarrollo del sistema de *SHM*, si bien este proyecto solo abarcó, a nivel práctico, el diseño de la herramienta de detección de anomalías mediante algoritmos de reconocimiento de patrones estadísticos.

4.2. EVALUACIÓN OPERACIONAL

4.2.1. Descripción de la estructura instrumentada

El puente Beltrán se encuentra en el kilómetro 119+500 de la Autopista Guadalajara - Colima (México). Tiene una longitud total de 297.49 m que se distribuye en 4 vanos. El tablero de hormigón pretensado es de tipo cajón unicelular con canto variable entre 4.40 m en centro de vano central y 7.50 m en secciones sobre pilas 2, 3, 4. El espesor de las almas de las secciones es de 0.5m. Las losas superior e inferior tienen espesores de 0.50 y 0.75 m respectivamente. Las pilas 2 y 3 son de sección tipo cajón, huecas con espesor 0.40 m. Presentan una altura de 24.24 m, ancho constante de 6.00 m y 1.50 m de canto. El contacto tablero – pila se establece a través de aparatos de apoyo tipo POT.

La pila nº 4 se encuentra rígidamente conectada al tablero materializado en un punto fijo de la estructura y tiene 120.45 m de altura y sección de cajón variable. El ancho y el canto de la base son de 6.00 m, mientras que en cabeza el canto se reduce a 4.00 m, variando linealmente con la altura mediante una relación 1:60. El espesor de los paramentos de esta pila es de 0.80 m.

La singularidad del puente se encuentra en el empotramiento entre el tablero y la pila 4, la combinación de la pila alta con pilas bajas y la elevada longitud del vano central.



Figura 16 Vano central y pila nº 4 del puente Beltrán (Cortesía de INECO; extraído de [T.4]).

4.2.2. Motivación de la instrumentación

La propuesta de instrumentar el puente del Beltrán surge de la necesidad de evaluar el comportamiento de los apoyos tipo POT. Dada la edad del puente, estos aparatos de apoyo representaban una tecnología desconocida que requería un seguimiento y análisis de comportamiento.

Además, dadas las características del puente, se buscaba poder demostrar el buen funcionamiento de estos aparatos, así como su necesidad o no de sustitución (por encastramiento, pérdida de capacidad deslizante u otras posibles degradaciones) puesto que la operación de sustitución implica un fuerte impacto en el tráfico, y por tanto debería estar rigurosamente justificada, lo cual no es posible mediante las técnicas de inspección convencionales.

4.3. INSTRUMENTACIÓN Y PROCESAMIENTO

4.3.1. Descripción del sistema de instrumentación

En este apartado se presenta el sistema de instrumentación diseñado sobre el puente Beltrán, cuyo objetivo principal era aportar información general sobre el comportamiento del puente frente a acciones de tipo lento o cuasi – estáticas, como la temperatura.

La instrumentación del puente Beltrán se realizó exclusivamente con sensores de tecnología basada en la fibra óptica.

Dadas las particulares características del viaducto, se monitorizó el comportamiento estructural de la pila más elevada (nº 4), a través de la medición de las inclinaciones y vibraciones en cabeza de pila. También se instalaron sensores en diferentes puntos del viaducto para registrar los desplazamientos del tablero en las otras dos pilas y en los estribos, así como las vibraciones en los vanos contiguos a la pila 4. Además, se midieron micro-deformaciones en los tres vanos de la estructura.

Las variables a controlar y los sensores empleados se presentan a continuación:

- **Movimiento de pilas:** Se instalaron dos clinómetros unidireccionales en la cabeza de la pila número 4, uno para cada dirección para la medición de los giros longitudinales y transversales respecto a los ejes perpendiculares del plano horizontal en dicha pila y, con ello, las inclinaciones verticales asociadas.
- **Desplazamiento relativos estribo/pila – tablero:** Se instalaron un total de 6 sensores de precisión para el registro de los desplazamientos de tablero. En la pila número 2 y en el estribo 1 se instaló un sensor de desplazamiento longitudinal. En la pila 3 y el estribo 2, lado Colima, se instalaron dos sensores de desplazamiento: uno longitudinal y otro transversal.

- **Aceleraciones verticales y horizontales transversales en tablero:** Se instalaron 3 acelerómetros verticales, dos aproximadamente en la mitad de los vanos 3 y 4 y otro sobre la pila nº 4. Los acelerómetros para el registro de las aceleraciones horizontales transversales se emplazaron en la misma posición que los acelerómetros verticales.
- **Micro-deformaciones en el tablero:** En cada una de las tres secciones transversales principales de la estructura se instalaron, de forma simétrica, tres extensómetros longitudinales próximos a la fibra interior de ambas almas de la sección, en el interior del cajón y de forma simétrica respecto del eje longitudinal.

De todos los datos registrados, el estudio estadístico se centró en la información de los movimientos relativos entre tablero, pila y estribos que se compone de 4 sensores de desplazamiento denominados como: THL1, THL3, THL4 y THL8.

En lo que se refiere a la instalación del sistema, por tratarse de un viaducto accesible y visitable, la mayor parte de la instrumentación se realizó por el interior del mismo. Sin embargo, debido a la imposibilidad de acceder a la zona de apoyo de las cabezas de pilas por el interior del viaducto, fue necesario emplear un equipo de trabajos en altura para instalar algunos sensores como los transductores de hilo que registran el movimiento relativo del tablero y las pilas.

El equipo de adquisición de datos de fibra óptica permitió tener una frecuencia de muestro elevada en todos los sensores, cercana a los 200 Hz, si bien los datos se almacenaron con una frecuencia inferior, según las características dinámicas. Los desplazamientos de tablero y las medidas de los clinómetros, por tratarse de fenómenos de carácter estático, se registraron con frecuencias de adquisición bajas. Por su parte, los sensores cuya información tiene un carácter plenamente dinámico, como los acelerómetros, requirieron una frecuencia de adquisición y almacenamiento superior.

El Puesto de Control Local (PLC) se ubicó dentro del viaducto, en las cercanías del estribo 1, lado Guadalajara, donde se estableció la fuente de suministro para la alimentación de los sensores y demás equipos, procedente de un sistema de paneles

solares. Además, toda la información generada por los equipos de medición se unificó en este puesto de control local, por medio de un concentrador.

Mediante un servidor para la adquisición de datos y diferentes aplicaciones web, se consiguió diseñar un sistema de control remoto de la instalación que permitiera la visualización de los datos registrados en todo momento.

Como ya se mencionó, las mediciones se realizaron de forma continua mediante registro constante de datos por instrumentación automática, durante un periodo de aproximadamente un año. Así, los datos registrados por cada sensor recogieron el comportamiento del puente bajo distintas condiciones de carga y ambientales, proporcionando información general de su estado de funcionamiento, que fue posteriormente analizada.



Figura 17 Detalle de un anclaje de fibra óptica y caja de conexiones en tablero (Cortesía de Ineco; extraído de [T.4])

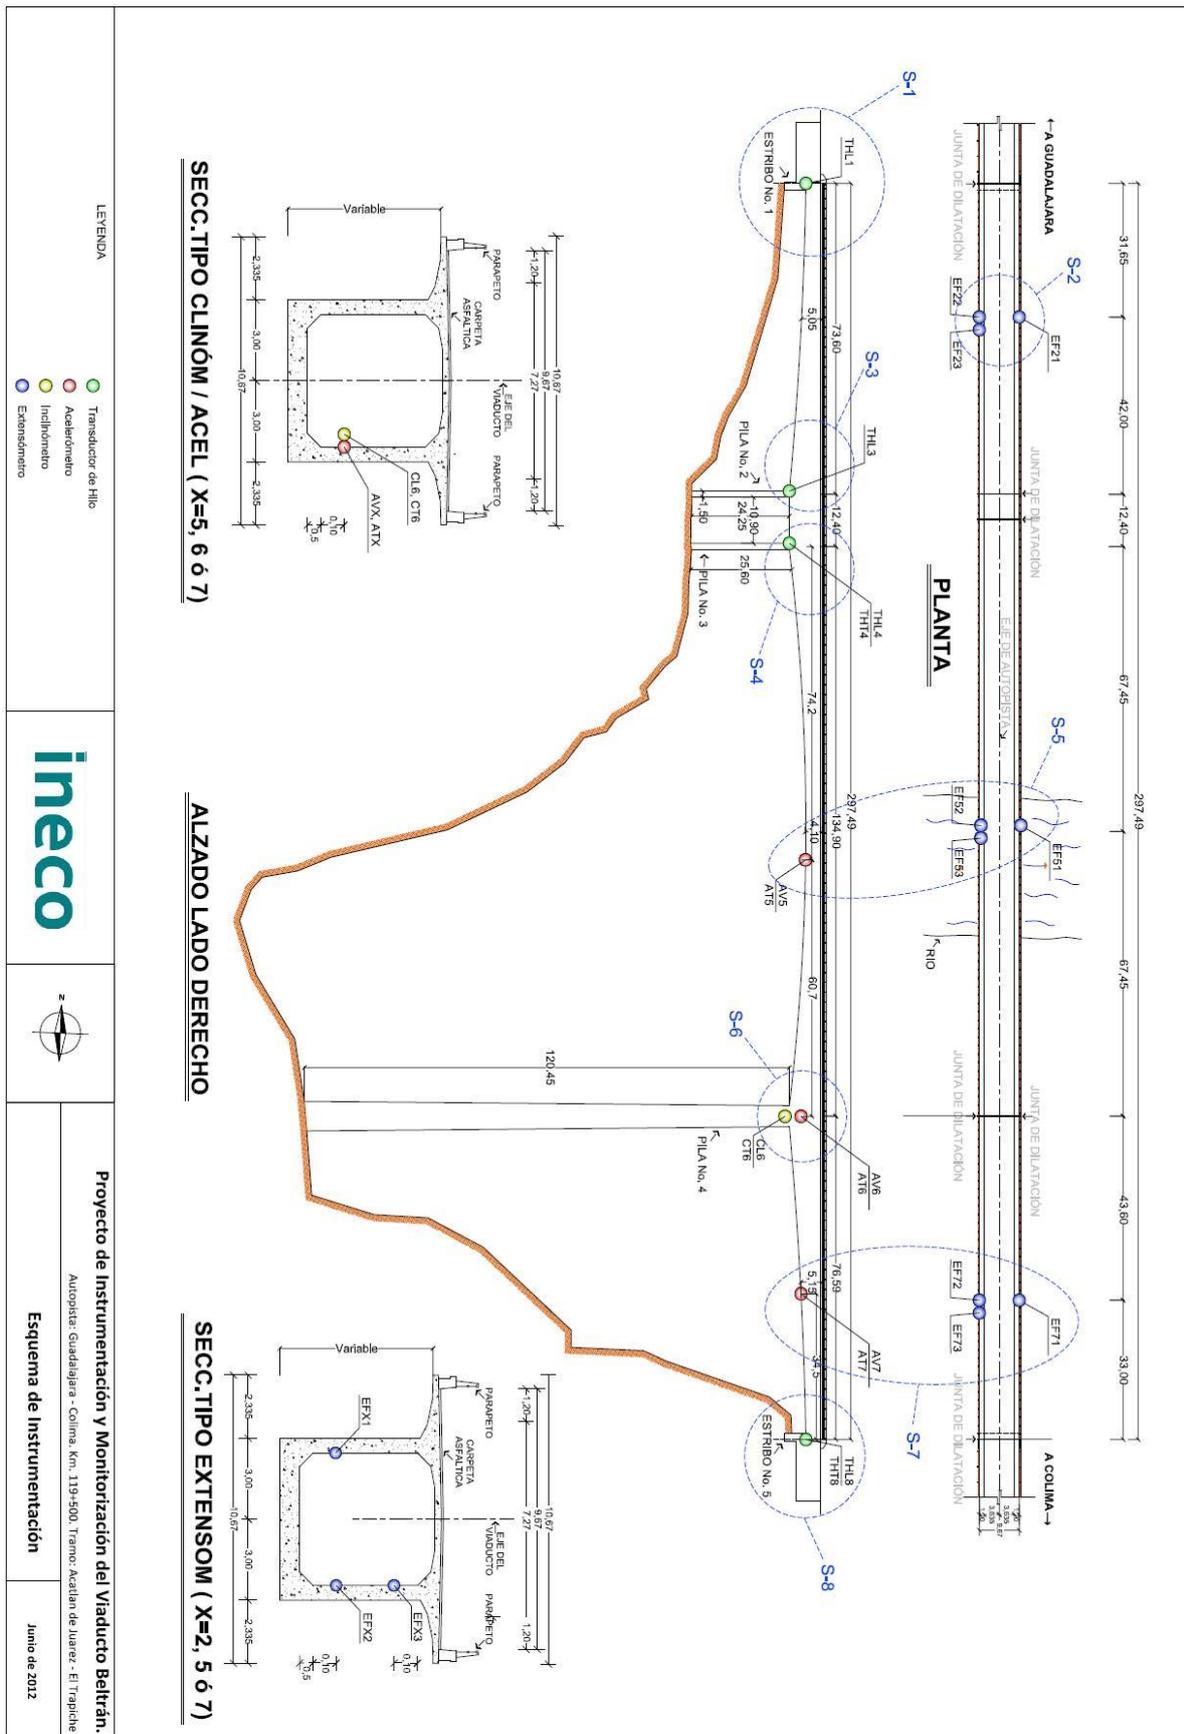


Figura 18 Esquema de instrumentación del puente Beltrán (Cortesía de Ineco; extraído de [T.4])

4.3.2. Adquisición y transmisión de datos

El monitoreo se efectuó de forma continua durante un año, es decir, mediante un registro constante e Instrumentación automática, ya que esta metodología permite realizar el análisis completo de los datos obtenidos en un período concreto de tiempo, de forma las señales obtenidas en cada sensor recojan el comportamiento del viaducto tanto al paso de los distintos vehículos como por las condiciones ambientales. Cada 10 minutos se extrajeron los estadísticos de interés (máximo, mínimo, media, etc.) para sustituir a los datos registrados de forma continua y reducir la cantidad de información almacenada por el sistema, que adoptó un carácter discreto, de forma que cada serie disponía de 268 mediciones.

La transmisión de datos se pretendía realizar en tiempo real, puesto que eso permitiría un control actualizado de los registros mediante un sistema de seguimiento de la evolución de la estructura. Sin embargo, los datos fueron facilitados periódicamente a mes vencido. Gracias a estos datos y mediante las nuevas técnicas de aprendizaje automático, fue posible configurar un algoritmo de detección anticipada de anomalías, que permite proporcionar diagnósticos sobre el estado de la estructura prácticamente en tiempo real.

4.3.3. Procesamiento de datos

El objetivo fundamental de esta fase reside en evaluar la calidad de los datos registrados. Como ya se mencionó, el control de calidad se efectuará sobre los datos de los movimientos relativos tablero – pila y tablero – estribo, medidos por los transductores de desplazamiento. Para poder poner en práctica las técnicas de control estadístico mediante gráficos de control, será necesario asegurar que se han eliminado todas las posibles fuentes conocidas que inducen variabilidad en los datos, puesto que lo que se pretende controlar es, precisamente, la parte no explicable de la señal.

La representación de las series temporales de los valores medios de desplazamiento muestra una tendencia cíclica anual debida a la acción de la temperatura. Esto permite ajustar una función sinusoidal de período anual a descontar de la serie de datos originales, dando lugar a una nueva señal modificada cuyos valores varían en un rango mucho menor.

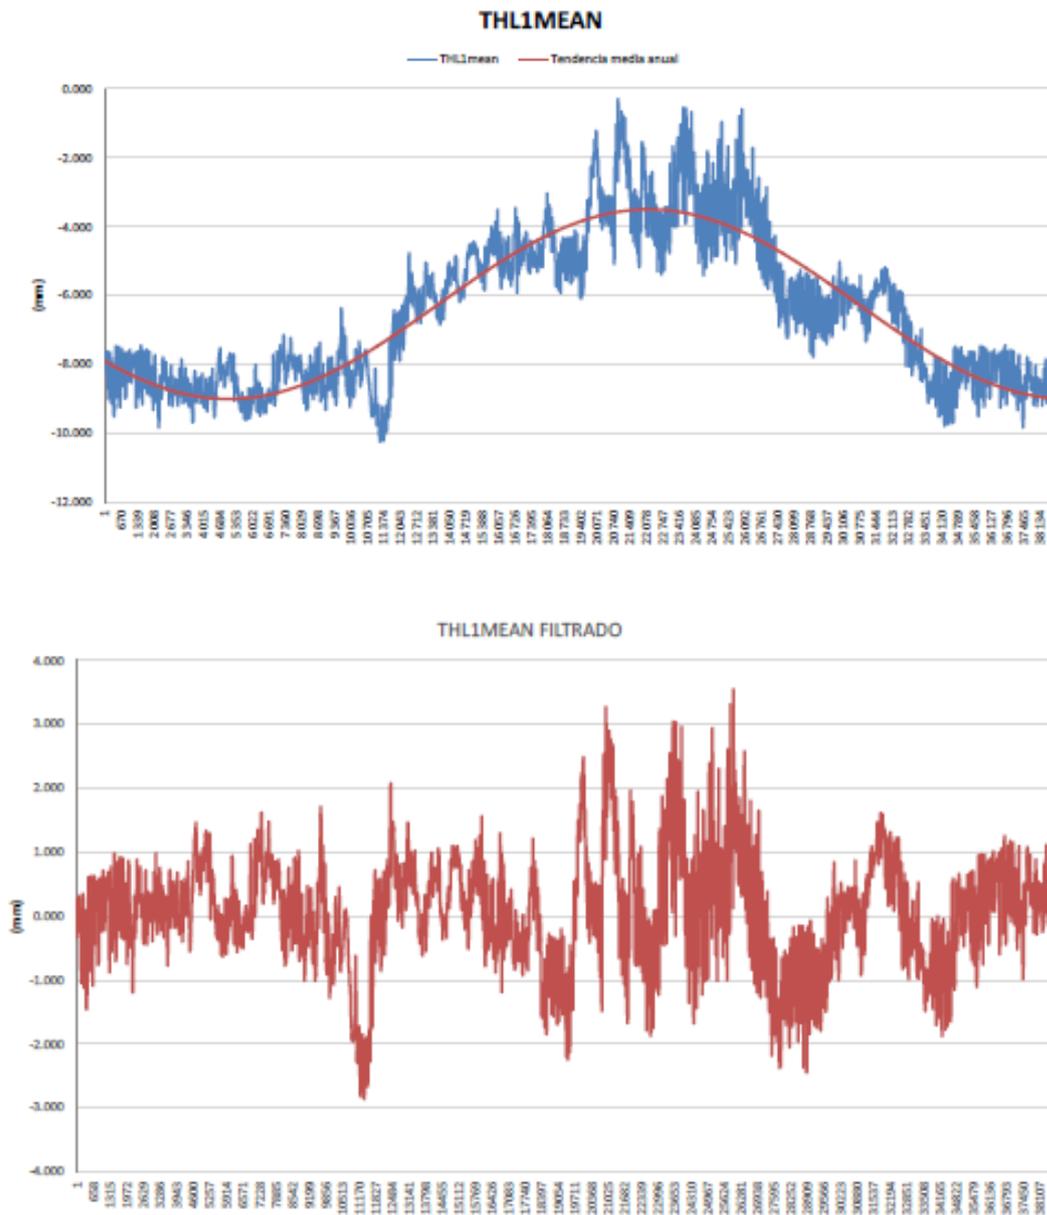


Figura 19 Filtrado de la componente cíclica debida a la temperatura en la serie temporal anual (Extraído de [T.4])

Como puede observarse en la figura, los datos filtrados quedan centrados en un valor aproximadamente constante y no se aprecian tendencias ni periodicidades, además de reducirse la variabilidad de la serie cerca de un 40%. Sobre esta nueva serie filtrada se aplicarán los Diagramas de Control Estadístico, como se muestra en la siguiente figura:

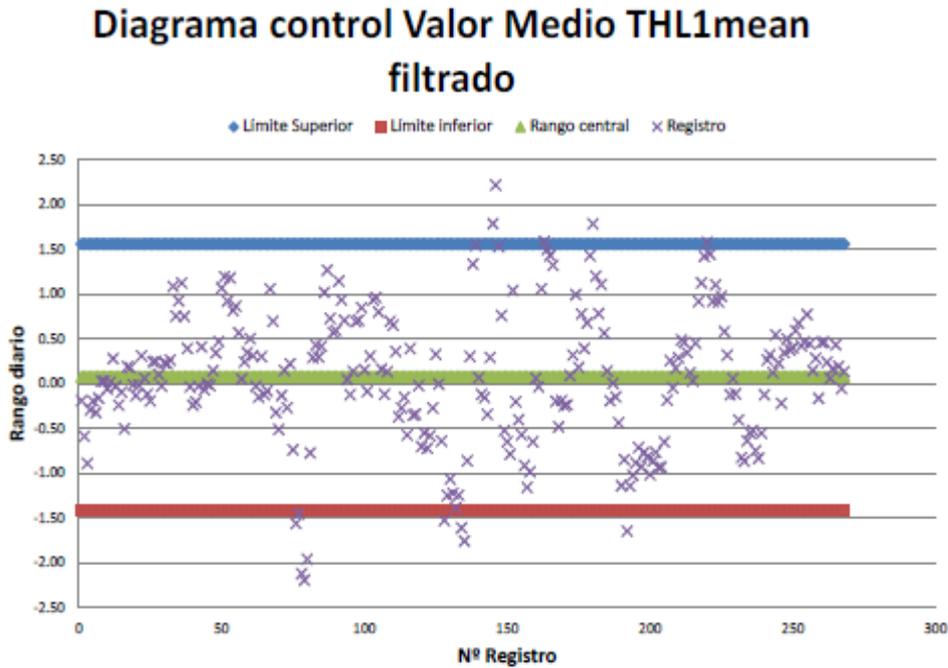


Figura 20 Diagrama de Control estadístico del valor medio de la serie temporal filtrada (Extraído de [T.4])

Atendiendo a los diagramas de control realizados para la media y el rango de las series de datos asociadas a los cuatro sensores del estudio, se puede decir que las señales se encuentran bajo control y que por tanto los datos se corresponden con un funcionamiento normal de la estructura al no existir factores ajenos que induzcan variabilidad.

A pesar de que hay algunos puntos que sobrepasan los límites del diagrama, hay que tener en cuenta que se está trabajando con medidas milimétricas, por lo que los puntos fuera de control no son significativos dadas las dimensiones de la estructura y se puede concluir que la calidad de los datos son lo suficientemente fiables como para que los posteriores estudios estadísticos desarrollados sean mínimamente robustos.

4.4. POSTPROCESO

4.4.1. Introducción

En esta etapa se aborda el diseño de los modelos estadísticos que permiten aprovechar la información disponible del proceso de monitorización para evaluar el estado de la estructura. Como se planteó en los objetivos, el presente proyecto trata de aportar un enfoque multi-escala en la detección anomalías en la estructura, continuando con una de las líneas de investigación planteadas en la tesis (de DGS) que da origen a este proyecto, que propone la matriz de correlaciones (o covarianzas) como punto de partida para desarrollar una herramienta de diagnóstico global sobre el estado de la estructura.

Por tanto, de acuerdo con este enfoque, se aplicará el procedimiento desarrollado en el apartado 3 del capítulo 3 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 software gratuito de estadística “R”.

4.4.2. Creación del modelo de referencia

Análisis de Componentes Principales

El proceso de monitorización proporciona una muestra de datos que se corresponden con el estado no dañado de la estructura, que incluye las mediciones de cada uno de los sensores de desplazamiento ubicados en la estructura.

Estos datos se pueden disponer de forma matricial, donde cada columna representa una variable o sensor y cada fila es un vector con las mediciones de todos los sensores en un determinado instante. En la siguiente figura se muestra una fracción de la matriz de dimensiones $(n \times m)$, siendo n el número de mediciones (268) y m el número de sensores (4).

```
> xdata
```

	v1	v2	v3	v4
1	-7.854568	-4.705778369	0.51930838	2.45874088
2	-8.316593	-4.978686688	1.44835591	-0.49490313
3	-8.666887	-5.158799158	1.32909661	0.28891971
4	-8.130966	-5.768574889	1.84919973	0.06795362
5	-8.100705	-4.891034485	1.02962813	0.26593665
6	-8.288327	-4.594491143	1.65491230	-0.29685091
7	-8.173414	-4.792187168	1.42248288	-1.24151922
8	-8.043123	-4.836305835	1.27210398	-1.66700315
9	-8.108103	-3.931364821	0.87461740	2.01027678
10	-8.234738	-4.568247634	1.59760847	1.42547050

Figura 21 Extracción de los 10 primeros elementos de la muestra de referencia

Un aspecto importante, sobre todo cuando se trabaje con sensores de diversas tecnologías o con magnitudes diferentes, es la normalización de los datos. De esta manera se consiguen muestras homogéneas para cada variable, con parámetros estadísticos idénticos: media nula y desviación estándar unitaria.

A continuación, se muestran los 10 primeros vectores de la matriz normalizada:

```
> Xnorm
```

	v1	v2	v3	v4
[1,]	-0.648354790	-0.722739006	0.073421229	-0.425987797
[2,]	-0.866017300	-0.845298469	0.338200436	-0.796281429
[3,]	-1.031043032	-0.926184562	0.304211450	-0.698014812
[4,]	-0.778567509	-1.200026658	0.452441208	-0.725716978
[5,]	-0.764311233	-0.805935041	0.218862719	-0.700896161
[6,]	-0.852701040	-0.672761406	0.397069153	-0.771451939
[7,]	-0.798565055	-0.761544038	0.330826604	-0.889883497
[8,]	-0.737184016	-0.781357139	0.287968509	-0.943225738
[9,]	-0.767796769	-0.374960276	0.174684552	-0.482211024
[10,]	-0.827455258	-0.660975799	0.380737520	-0.555527254

Figura 22 Extracción de los 10 primeros elementos de la muestra de referencia normalizada

Una vez normalizados los datos se obtiene la matriz de covarianzas, Cx :

$$Cx = \begin{pmatrix} 1.0000000 & 0.8394628 & -0.7966713 & 0.7963956 \\ 0.8394628 & 1.0000000 & -0.8670015 & 0.5867575 \\ -0.7966713 & -0.8670015 & 1.0000000 & -0.5863167 \\ 0.7963956 & 0.5867575 & -0.5863167 & 1.0000000 \end{pmatrix}$$

En esta matriz, los elementos que se encuentran fuera de la diagonal se corresponden con los factores de correlación entre pares de variables o sensores. Cuanto mayores sean estos factores, mayor nivel de redundancia existirá entre los pares de variables. Mediante el análisis de componentes principales, los datos se proyectan sobre una nueva base ortonormal a través de las direcciones de máxima varianza y mínima redundancia, que permiten exhibir la información de interés para la detección de daños con la mínima cantidad de datos.

Estos componentes principales son los vectores propios de la matriz de covarianzas, y su peso en el análisis depende de la cantidad de la varianza original que contengan, que se refleja directamente en la magnitud del autovalor correspondiente. A continuación, se muestran los vectores propios del modelo de estudio:

DESCOMPOSICIÓN EN VECTORES PROPIOS				
	PC1	PC2	PC3	PC4
1	-0.5299735	-0.1427128	0.4595205	0.6982851
2	-0.5106842	0.4169128	0.4527573	-0.6003301
3	0.5033348	-0.4340558	0.7243157	-0.1833479
4	-0.4527515	-0.7857559	-0.2433486	-0.3440715

Los vectores propios se forman como una combinación lineal de las cuatro variables originales y, por tanto, estarán formados por cuatro componentes que los caracterizan. Esta información puede agruparse de forma matricial para configurar el modelo de transformación P , sobre el que se proyectarán los datos originales para obtener la muestra transformada. Sin embargo, antes de efectuar la transformación, conviene evaluar detalladamente los componentes, en busca de una simplificación del modelo, que permita trabajar con la menor cantidad de datos.

El análisis de componentes principales proporciona la siguiente información:

EVALUACIÓN DE LOS COMPONENTES				
	PC1	PC2	PC3	PC4
Valor Propio	3.24588974	0.5094305	0.14961288	0.0956332
Desviación Estándar	1.8016	0.7137	0.3868	0.30832
Proporción de varianza	0.8115	0.1274	0.0374	0.02377
Proporción acumulada	0.8115	0.9388	0.9762	1.0000

Del análisis de estos resultados, se observa que los vectores propios con mayor valor propio contienen una desviación estándar mayor y contienen una mayor proporción de la varianza de los datos originales. Por ejemplo, si atendemos a la proporción de varianza contenida, observamos que el primer componente abarca más del 80% (81.15%) de la varianza original total, mientras que el último se queda entorno al 2% (2.377%).

Esta información constituye un indicador claro de la importancia de los distintos componentes a la hora de representar el modelo, y permite discriminar aquellos vectores que jueguen un papel poco importante. En la siguiente figura se muestra esta información de forma gráfica:

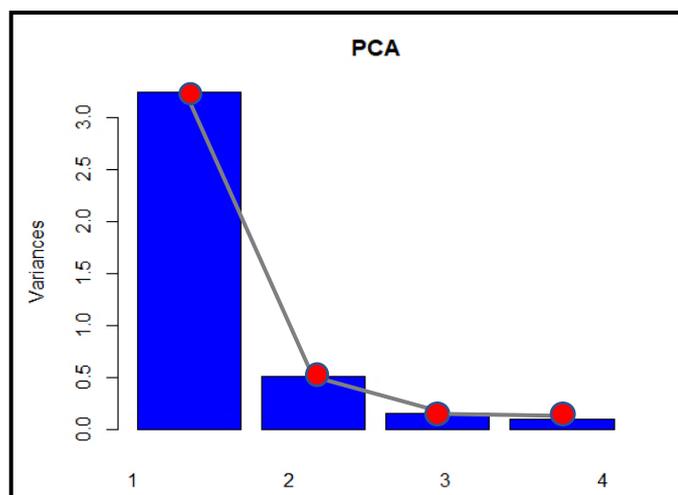


Figura 23 Análisis de Componentes Principales de la muestra de referencia

Una forma de seleccionar el número de componentes que participan en el modelo de transformación consiste en analizar la proporción de varianza acumulada. La proporción acumulada por todos los componentes debe corresponderse con el total de la variación presente en los datos originales, de ahí que en el último vector este valor sea la unidad.

Por tanto, dado que el nivel de varianza que queremos conservar en nuestro modelo depende de la cantidad de componentes incluidos, se debe llegar a un acuerdo entre ambas magnitudes. Un nivel de varianza aceptable suele estar entorno al 80 o 90 % del total. En nuestro caso, bastará con seleccionar los dos primeros componentes para abarcar casi un 94 %, por lo que se dispondrá de un modelo robusto con un número reducido de componentes.

Una vez seleccionados los componentes principales de interés, se puede configurar la matriz de transformación reducida, que contendrá en sus columnas los vectores propios correspondientes:

$$P = \begin{pmatrix} -0.5299735 & -0.1427128 \\ -0.5106842 & 0.4169128 \\ 0.5033348 & -0.4340558 \\ -0.4527515 & -0.7857559 \end{pmatrix} \quad (35)$$

La matriz de transformación P puede emplearse para transformar la matriz de datos original en un modelo de referencia reducido como resultado de la proyección sobre las direcciones principales seleccionadas: $T = Xdata \cdot P$. Esta información permite representar los datos y realizar una valoración cualitativa.

Cálculo de los índices de daño

En el ámbito de la detección de anomalías, el análisis de componentes principales se utiliza para calcular un indicador de daño que permita valorar cuantitativamente el estado de la estructura, y que constituye el eje central del algoritmo de control de la salud estructural.

El estadístico de Hotelling o T^2 proporciona una indicación de la variación de cada elemento de la muestra sobre el modelo de componentes principales. Por tanto, para cada vector de mediciones asociado a un determinado instante de tiempo i , el índice de daño se calculará como:

$$T_i^2 = \mathbf{x}_{vi} P \Lambda^{-1} P^T \mathbf{x}_{vi}^T \quad (36)$$

Donde P es la matriz de transformación reducida, y Λ se obtiene como la matriz diagonal que contiene los valores propios seleccionados:

$$\Lambda = \begin{pmatrix} 3.24588974 & 0 \\ 0 & 0.5094305 \end{pmatrix} \quad (37)$$

De forma complementaria, puede calcularse también el estadístico Q , que resulta mucho más sensible al daño debido a su menor orden de magnitud haciendo que cualquier mínimo cambio sea fácilmente observable, pero con la desventaja de que es más susceptible de generar falsas alarmas en el diagnóstico. Para cada elemento de la muestra se obtiene también el estadístico Q como:

$$Q_i = \mathbf{x}_{vi} (I - P \cdot P^T) \mathbf{x}_{vi}^T \quad (38)$$

Obtención del modelo estadístico de referencia

En este punto se dispone de una muestra de 268 elementos para cada tipo de indicador de daño, cuyo modelo estadístico puede obtenerse por medio de la función de densidad de kernel, cuyo fundamento teórico se explicó en el capítulo 3. Esta técnica permite obtener, para cada indicador, una función continua que representa el estado no dañado de la estructura y que servirá como modelo de referencia o patrón de comparación durante el funcionamiento de la herramienta.

Los modelos de referencia asociados a cada uno de los indicadores de daño se muestran a continuación:

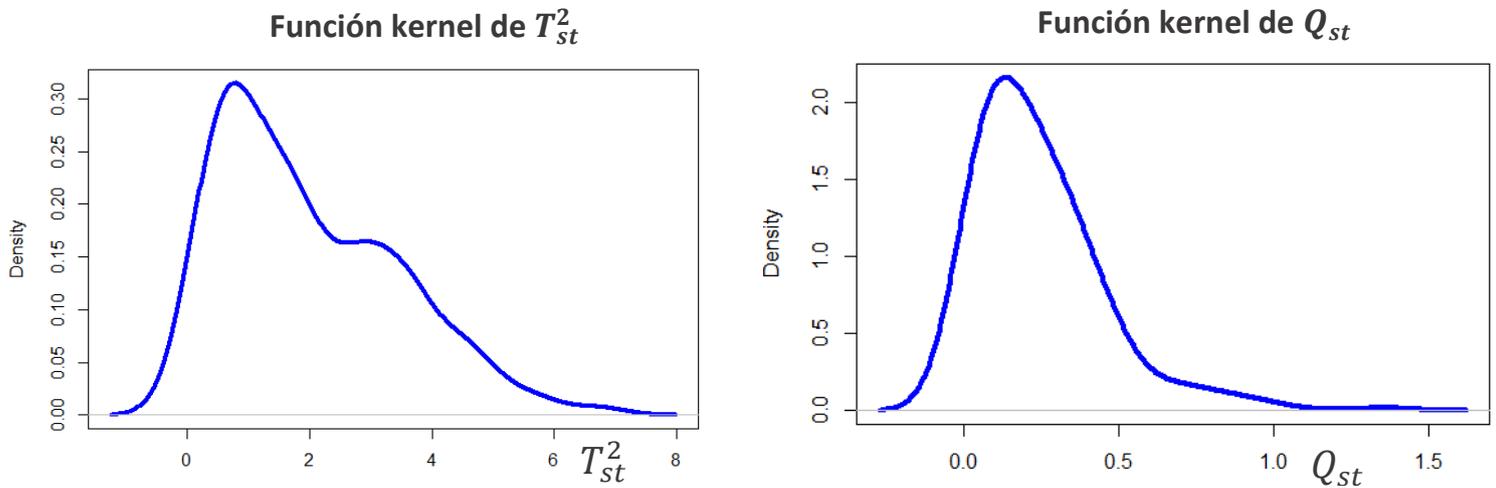


Figura 24 Funciones densidad de los indicadores de daño individuales

Por simplicidad, se suele trabajar con un indicador combinado o global, que tenga en cuenta la información proporcionada por los dos indicadores anteriores y la exprese mediante un valor único. Este indicador se designa como θ y se obtiene como:

$$\theta = T^2 + Q \tag{39}$$

De este modo, puede obtenerse fácilmente su función de kernel representativa del estado de referencia, que será la que se emplee en los siguientes apartados como modelo base o patrón.

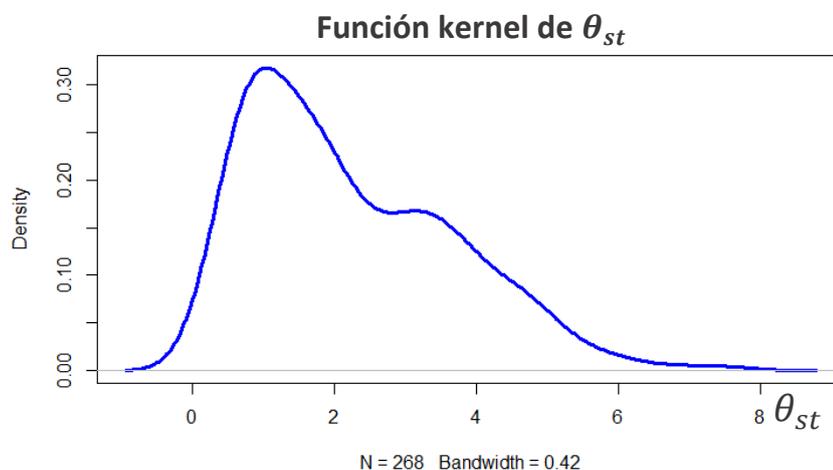


Figura 25 Función densidad de kernel del indicador combinado

Las propiedades estadísticas de los tres indicadores se recogen en la siguiente tabla:

PROPIEDADES ESTADÍSTICAS			
	INDICADOR T^2	INDICADOR Q	INDICADOR θ
MEDIA	1.9925	0.2438	2.2363
DESVIACIÓN ESTÁNDAR	1.4712	0.2055	1.4559
PARÁMETRO h	0.42	0.09	0.42

4.4.3. Establecimiento del nivel de confianza

Para poder distinguir entre los dos posibles estados de la estructura es necesario establecer un límite que permita clasificar los nuevos índices de daño según su probabilidad de pertenecer al modelo de referencia.

Para definir este límite, se debe asumir un nivel de incertidumbre a la hora de realizar los diagnósticos, que caracteriza la fiabilidad de la herramienta diseñada. En este caso, se asumió un nivel de confianza del 95% (nivel de incertidumbre del 5%) para poder obtener una herramienta lo suficientemente robusta en cuanto a falsos positivos.

El procedimiento a seguir para cada uno de los indicadores de daño fue el siguiente:

- Se calculó el percentil 95 sobre la función kernel, que proporcionó el indicador correspondiente al límite de aceptación (solo el 5% de los datos de la muestra son superiores a este valor).
- Se evaluó este indicador para determinar su probabilidad (densidad) mínima necesaria para pertenecer al modelo de referencia.

A pesar de que se estableció el indicador combinado como el patrón de comparación que permitiera evaluar el estado de la estructura, también se calcularon los límites de aceptación para los otros indicadores, para poder analizar el origen de la desviación.

Como resultado, se obtuvieron los siguientes resultados:

LÍMITES DE ACEPTACIÓN			
	INDICADOR T^2	INDICADOR Q	INDICADOR θ
PERCENTIL 95	4.7512	0.6591	4.9225
PROBABILIDAD LÍMITE	0.0634	0.1762	0.0688

Como se observa en la tabla, el indicador combinado θ presenta un valor máximo admisible de 4.9225, que se corresponde con una probabilidad en la función densidad de 0.0688. Por tratarse de una distribución de una cola, cualquier nuevo indicador registrado que supere el valor límite, será considerado como perteneciente al estado dañado.

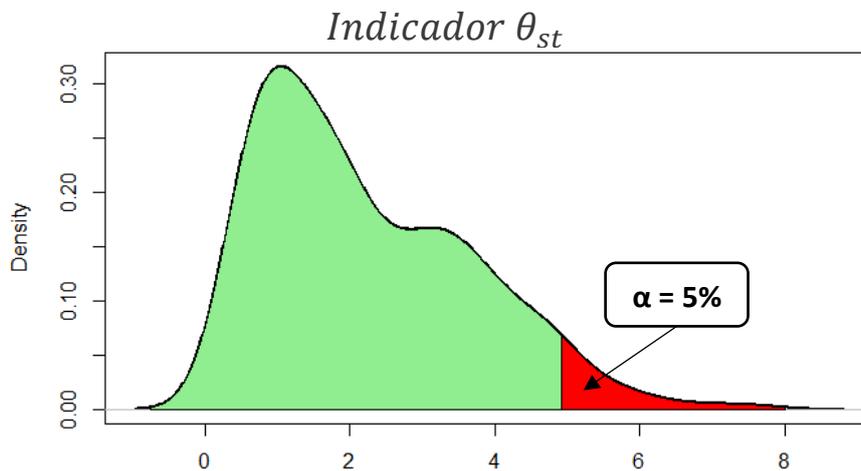


Figura 26 Delimitación de los estados de clasificación sobre el modelo de referencia con un 5% de incertidumbre

En la figura 26 se muestra, de forma gráfica, la delimitación entre los dos estados para el indicador de daño combinado. La zona sombreada en color verde, que incluye el 95% por ciento de los datos de la muestra, se corresponde con el estado no dañado de la estructura, mientras que la zona sombreada en color rojo contiene los índices de daño correspondientes al estado dañado.

Mediante esta visualización resulta sencillo comprender el concepto de falso positivo: cuando la herramienta registre un nuevo indicador perteneciente al estado no dañado cuya magnitud sea superior al límite establecido (perteneciente a la zona roja), lo clasificará erróneamente en el estado dañado. Mediante el establecimiento del límite de confianza se restringe la cantidad de falsos diagnósticos que puede tolerar el sistema.

4.4.4. Validación de la herramienta

Generación de la muestra de Validación

Una vez diseñado el algoritmo de detección de anomalías, es necesario comprobar que funciona adecuadamente con otros datos antes de implementar la herramienta definitivamente en el sistema de Monitorización Estructural. En el caso del puente de este estudio, no existía información correspondiente a otro proceso de monitorización, por lo que los datos tuvieron que generarse de forma sintética mediante simulación.

Dado que se tienen que generar datos ficticios de las mediciones de cuatro sensores durante varios instantes de tiempo consecutivos, el primer paso consiste en analizar las relaciones existentes entre los distintos sensores para los datos de la muestra de referencia, a fin de establecer unos modelos lineales de correlación entre variables.

De forma gráfica, la siguiente figura muestra los diagramas de dispersión que relacionan a los cuatro sensores:

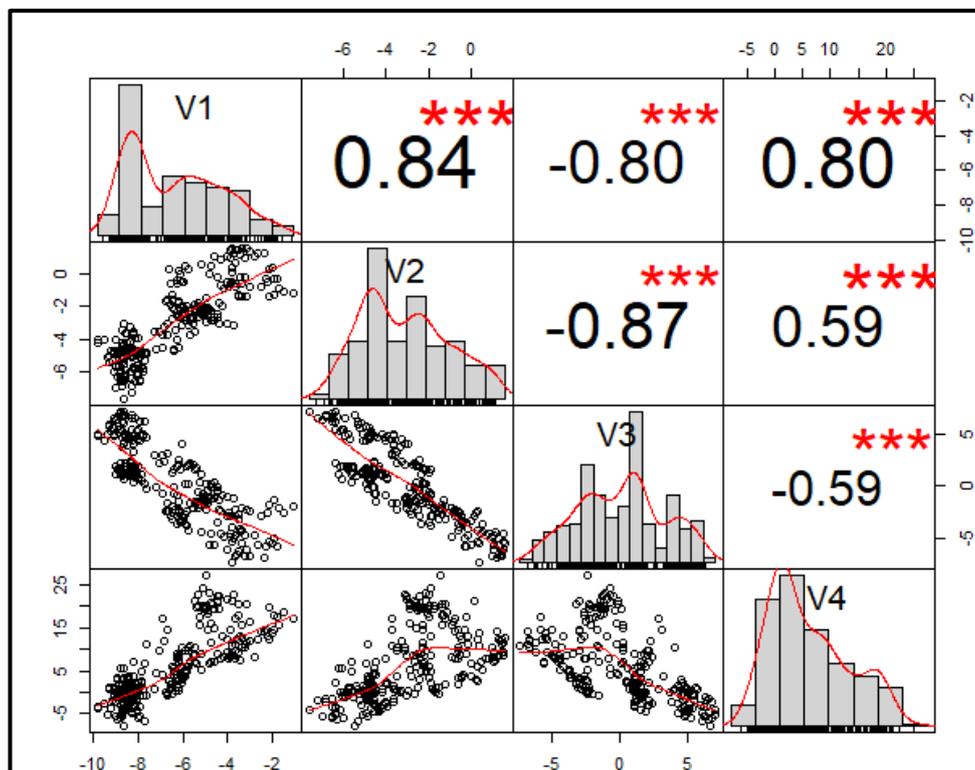


Figura 27 Diagramas de dispersión y correlaciones entre sensores

En la diagonal, donde se presentaría la correlación de cada variable consigo misma (1), se incorpora el histograma de la muestra asociada a cada sensor, acompañada de la función kernel correspondiente. Esta gráfica permite observar claramente que las correlaciones de todos los sensores con respecto al sensor 1 son las más elevadas, entorno al 0.8 en todos los casos. Por ello, el sensor 1 será utilizado como punto de partida para generar una muestra ficticia y, a continuación, se obtendrán las muestras asociadas a los demás sensores por medio del modelo de correlación lineal que guardan con respecto a dicho sensor.

Para generar una muestra aleatoria correspondiente al **sensor 1**, se expresó su comportamiento estadístico por medio de la función continua de kernel, del mismo modo que se hizo para trabajar con los indicadores de daño.

Sobre esta función se obtiene una muestra de datos que tengan un comportamiento estadístico similar, lo cual se consigue de forma más segura restringiendo los límites de muestreo a la zona central de la distribución.

En este caso, se generó una muestra de 10.000 elementos para reproducir con mayor fidelidad el comportamiento estadístico original. A continuación, se presenta la distribución de la muestra original de los datos reales junto con la distribución correspondiente a los datos generados mediante simulación, observándose que tienen un comportamiento similar. Las diferencias que se puedan apreciar proceden de que ha cambiado el tamaño de la muestra, y, en consecuencia, el parámetro h.

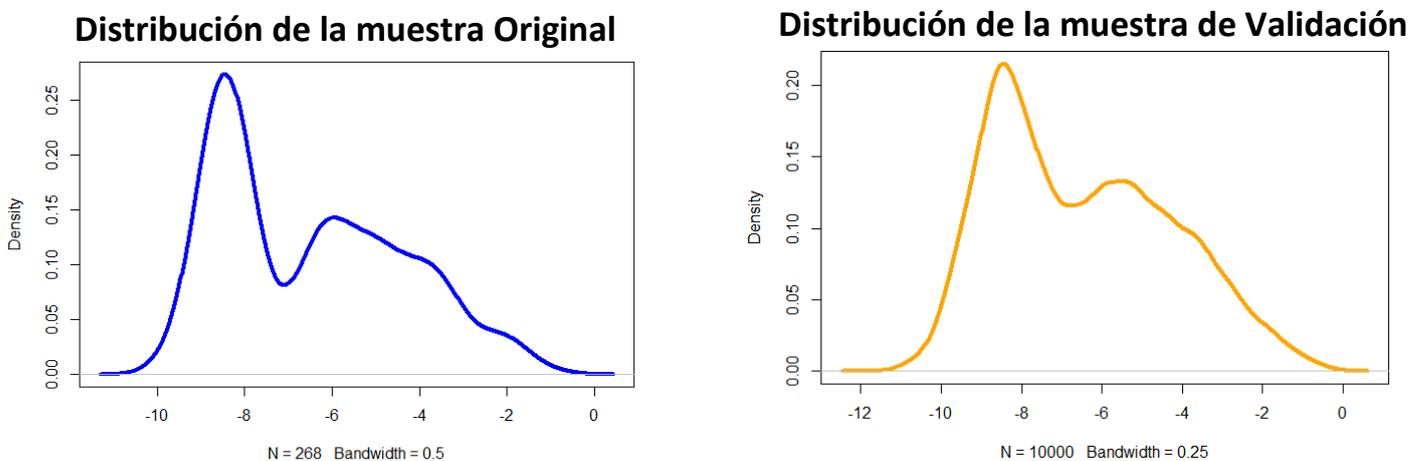


Figura 28 Función kernel de las muestras original y de validación. Comparación

En la siguiente tabla se recogen los valores estadísticos que caracterizan ambas muestras:

PROPIEDADES ESTADÍSTICAS (sensor 1)		
	Muestra Original	Muestra de Validación
TAMAÑO	268	10000
MEDIA	-6.4783	-6.4909
DESVIACIÓN ESTÁNDAR	2.1227	2.2413
PARÁMETRO h	0.5	0.25

Una vez se dispone de la muestra sintética del sensor 1, los datos correspondientes a los demás sensores se obtendrán mediante los modelos de regresión lineal correspondientes, que de forma general adoptarán una expresión tipo: $\hat{y} = b_0 + b_1 \cdot x$

Teniendo en cuenta que los valores reales no guardan una relación exactamente lineal, se calcularán añadiendo un error o residuo que sigue una distribución normal con media cero y desviación igual a la de la muestra del sensor correspondiente, es decir: $y_i = \hat{y}_i + e_i(\sim N(0, \sigma^2))$

Para cada sensor, el modelo lineal que permite obtener la muestra correspondiente a partir de los datos ficticios del sensor 1, es la siguiente:

$$\widehat{DF3} = 2.6085 + 0.8806 \cdot DF1 \quad (40)$$

$$\widehat{DF4} = -8.2696 - 1.3169 \cdot DF1 \quad (41)$$

$$\widehat{DF8} = 25.2441 + 2.9927 \cdot DF1 \quad (42)$$

Para obtener los datos de la muestra, se añadirá un valor residual para cada nuevo registro tomando un valor aleatorio de la distribución normal del residuo asociado al sensor correspondiente.

A continuación, se muestran los gráficos de dispersión y las correlaciones existentes entre los datos ficticios registrados por los cuatro sensores, verificando que se conservan las relaciones originales.

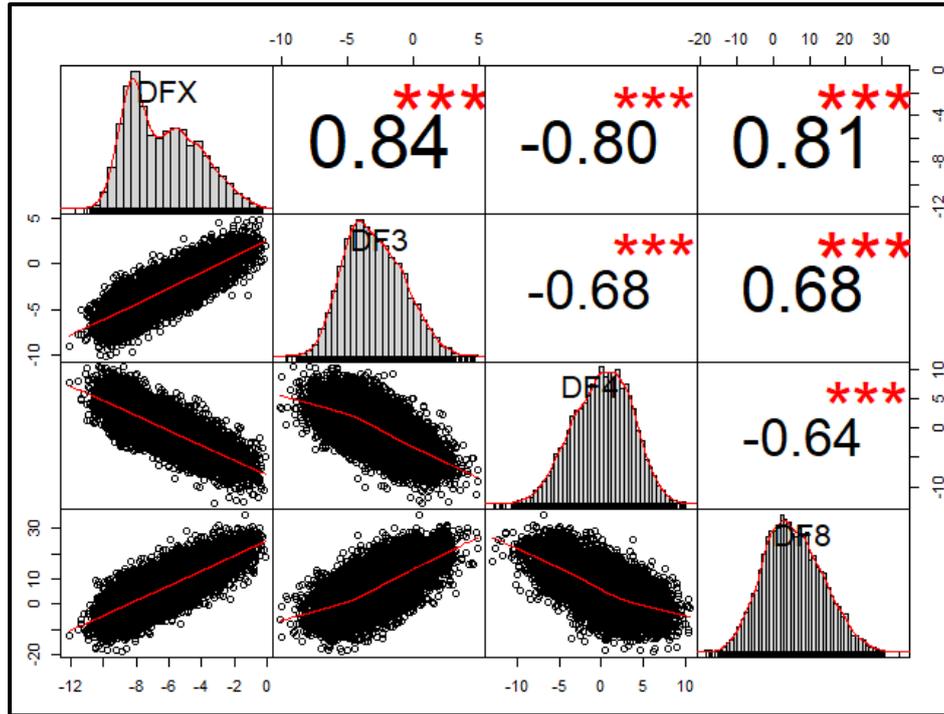


Figura 29 Diagramas de dispersión y correlaciones entre sensores de la muestra de validación

Obtención del modelo de Validación

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 índices de daño se calcularán mediante las matrices de transformación (P y Λ) asociadas al estado no dañado de la estructura para poder efectuar la comparación con respecto al modelo de referencia. Para un instante cualquiera i , las expresiones de cálculo serán:

$$T_i^2 = \mathbf{x}_{vi} P \Lambda^{-1} P^T \mathbf{x}_{vi}^T \quad (43)$$

$$Q_i = \mathbf{x}_{vi} (I - P \cdot P^T) \mathbf{x}_{vi}^T \quad (44)$$

$$\theta_i = T_i^2 + Q_i \quad (45)$$

donde \mathbf{x}_{vi} es el vector de las mediciones de los cuatro sensores en el instante i .

De este modo, se dispone de una muestra de 10000 elementos para el indicador combinado de daño, cuya representación estadística mediante la función de densidad de kernel constituirá el modelo de validación.

Comparación de los modelos y validación

El último paso para validar la herramienta de detección de daños consiste en verificar que el algoritmo realiza diagnósticos correctos con los nuevos datos de trabajo.

Para ello, en primer lugar, se deben comparar los modelos de referencia y de validación correspondientes al indicador combinado. Ambos modelos deben quedar prácticamente superpuestos, debido a que pertenecen al estado de referencia de la estructura.

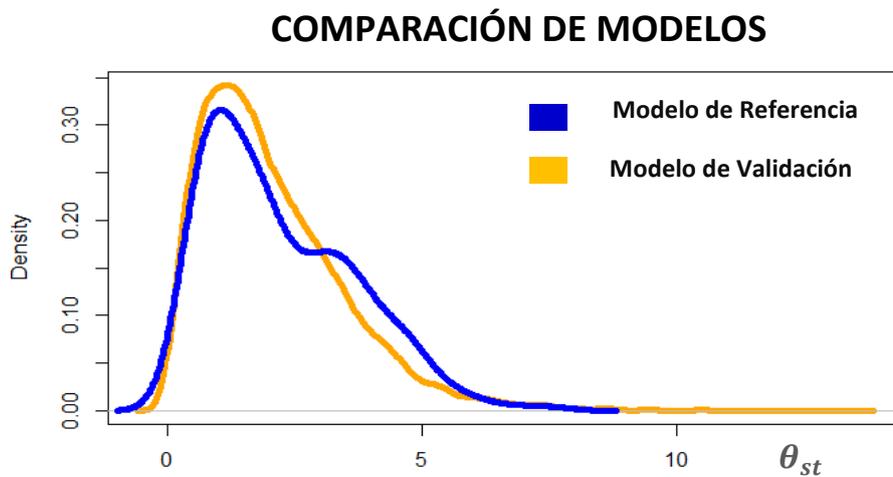


Figura 30 Comparación de los modelos estadísticos de referencia y validación

Se puede observar que el modelo de referencia y el de validación presentan comportamientos similares, si bien existen diferencias debido al cambio en el tamaño de muestra y a que el muestreo aleatorio se restringió a la zona central de la función de referencia del sensor 1. Para evaluar cuantitativamente la eficiencia de la herramienta, se calcula el Ratio de Falsas Alarmas, que determina la proporción de falsos positivos efectuados por el algoritmo sobre la muestra de validación.

Los porcentajes de falsas alarmas para el indicador global o combinado fueron:

$$RFA_{\theta} = \frac{N^{\circ} \text{ de indicadores} > \text{Límite}}{\text{tamaño de la muestra}} \cdot 100 = \frac{419}{10000} \cdot 100 = 4.19 \% \quad (46)$$

Con esto se verifica que la herramienta tiene un nivel de incertidumbre cercano al valor límite del 5% establecido para realizar diagnósticos fiables en el sistema de monitorización.

4.4.5. Implementación de la herramienta en el sistema de SHM

Una vez cumplimentadas todas las fases de diseño anteriores, se dispone de una herramienta de detección de fallos lista para su implementación en el sistema de monitorización de la salud estructural integrado en la estructura de estudio.

Reactivación del sistema de monitorización

Para poder evaluar el comportamiento actual de la estructura, será necesario registrar nuevos datos. Lo normal es que, por cuestión de costes, el sistema de monitorización solo esté activo cuando se necesite información sobre la estructura. Por ello, la herramienta podría activarse de manera intermitente coincidiendo con las tareas de inspección que suelen planificarse cada uno o dos años. Durante estas inspecciones, los sensores registrarían nuevos datos de manera continua y posteriormente se almacenarían los promedios de las mediciones realizadas cada 10 minutos para obtener una muestra del estado actual (desconocido) del puente.

Sistema de adquisición y transmisión de datos

Una vez reiniciado el sistema de instrumentación, la implementación íntegra del sistema de monitorización requiere el establecimiento de una comunicación entre la información proporcionada por los sensores y el hardware donde se integra la herramienta (PC).

Este sistema de monitorización está diseñado principalmente para su utilización durante revisiones periódicas, como apoyo a la información proporcionada por las técnicas de inspección visual empleadas actualmente, por lo que se plantea que, además del actual control remoto de la información registrada, se incorpore un sistema de adquisición de datos portátil que se comunique con el Puesto de Control Local durante el tiempo que dure la inspección para que la herramienta pueda evaluar el estado actual de la estructura en base a esos datos registrados.

Los sistemas portátiles se instalan temporalmente en la estructura para evaluar su estado real actualizado, o valorar el funcionamiento de sus componentes durante el tiempo que dura la reactivación del sistema de sensores, de modo que durante ese

tiempo se adquiere información que es transmitida a un PC que disponga de un software específico de adquisición de datos (CATMAN, LabView, FAMOS), y posteriormente estos datos son transferidos a la herramienta de evaluación para valorar el funcionamiento de la estructura.

Para la configuración completa de este sistema de comunicación, se deben seleccionar tres componentes fundamentales: el dispositivo de adquisición de datos, el bus de transmisión de datos, y la computadora de recepción y evaluación de los datos.

- La tarjeta de adquisición de datos debe seleccionarse en función de los tipos de señales que se vayan a medir, la necesidad de un circuito de acondicionamiento de señal integrado, la velocidad a la que se necesita efectuar el muestreo, el menor cambio detectable en la señal (resolución), y la cantidad de error admisible en las mediciones a realizar. En base a todos estos parámetros, para esta aplicación se seleccionó una tarjeta modular de adquisición de 32 entradas de 16 bits de resolución, con 20 canales disponibles y una velocidad de muestreo agregada de 1 MS/s (supone hasta 50kS/s para cada canal). La velocidad de transmisión total en Bytes por segundo será de 40 MB/s.
- El bus de transmisión se escogerá en base a la cantidad de datos que deban transmitirse por él, a los requerimientos de I/O, a la necesidad de sincronizar múltiples dispositivos, a la portabilidad y a la distancia existente entre las mediciones y el ordenador de evaluación. Con el objetivo de simplificar la instalación y reducir la cantidad de cable necesaria, se propone que la conexión se realice en el Puesto de Control Central, y por lo tanto el PC se ubicará a muy poca distancia de las mediciones. El bus deberá ser capaz de soportar los niveles de transmisión de datos impuestos por la tarjeta DAQ seleccionada, por lo que se seleccionará un bus Ethernet con un ancho de banda de 125 MB/s (compartidos), que soportará holgadamente los 40 MB/s.

- El último elemento a seleccionar es el ordenador de recepción y análisis de los datos registrados por los sensores. Por tratarse de un sistema de monitorización temporal, se seleccionará un ordenador portátil con capacidad para la instalación de un software específico de adquisición de datos, como CATMAN o LabView, que permita facilitar los datos a la herramienta de evaluación del estado de la estructura, desarrollada en el software de estadística R.

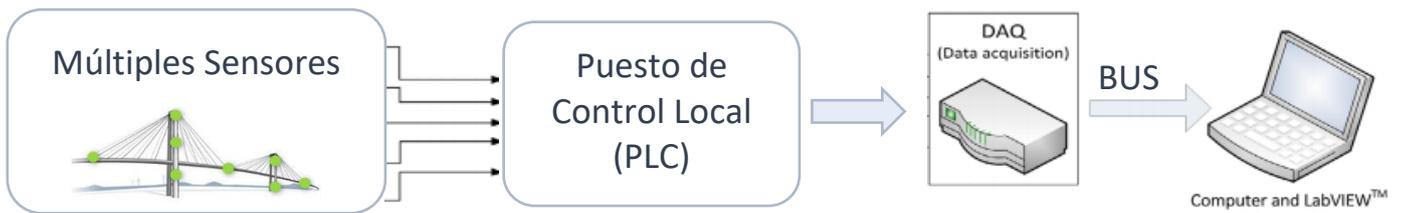


Figura 31 Sistema portátil de transmisión de datos

Esta instalación permitirá que los operarios del puente tengan acceso a la información procedente de la monitorización para realizar valoraciones en tiempo real, descargar los datos para un análisis más exhaustivo y detallado, y generar informes rutinarios. Además, este sistema de comunicación puede usarse como servidor adicional de apoyo para almacenar los datos procedentes de los sensores de forma temporal en caso de que se produzca una interrupción en la comunicación entre el puente y el servidor principal.

Evaluación

Los nuevos datos se introducirían a la herramienta de detección de fallos, que los procesaría automáticamente para obtener los índices de daño correspondientes y realizar una valoración de la situación de la estructura en base al indicador combinado. Esta información podría mostrarse de forma gráfica, actualizándose con cada nueva inspección.

En el caso de estudio analizado en el presente trabajo, se utilizó la información correspondiente al indicador combinado para evaluar el estado actualizado de la estructura. Sobre esta representación, se incorporó un código de colores que permitía tener en cuenta la información individual de los tres tipos de indicador.

- En caso de excederse los tres tipos de indicador (T^2 , Q y θ), el índice θ aparecerá en color rojo y con forma cuadrada.
- Si únicamente se excede el indicador combinado (θ), o este junto con alguno de los otros dos, entonces el indicador aparecerá en rosa.
- Si los datos no exceden el indicador θ , entonces se representarán en color verde, independientemente del valor que tenga cualquiera de los otros dos indicadores.

Con esta información se pretende minimizar el número de falsas alarmas proporcionadas por la herramienta, así como detectar tendencias en la evolución del indicador combinado que ayuden en la interpretación de los resultados.

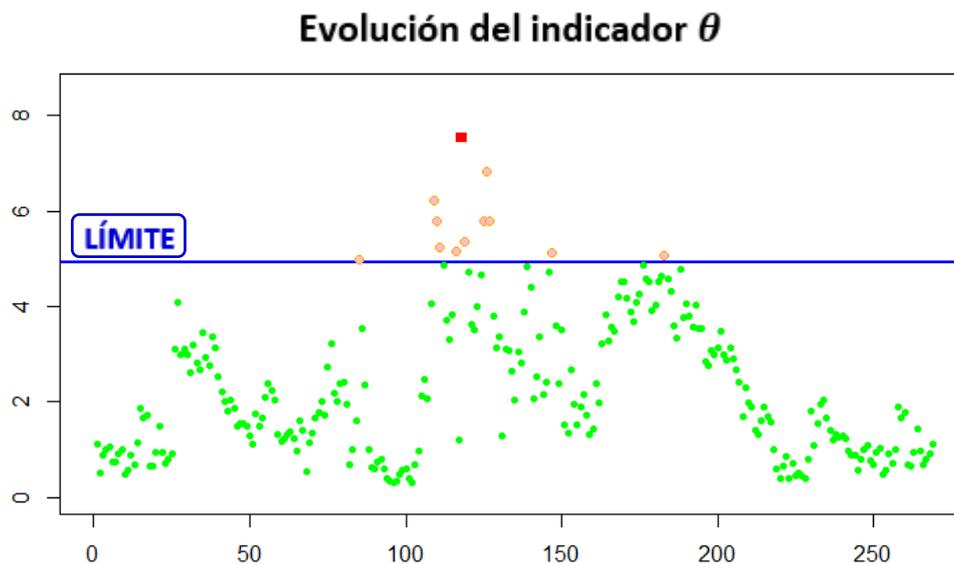


Figura 32 Evolución temporal del indicador combinado para la detección de comportamientos estructurales anómalos

En la siguiente figura se muestra el gráfico de evolución del indicador combinado de los datos de la muestra de referencia, donde se aprecia que hay un único dato que excede los tres límites.

CAPÍTULO 5

CONCLUSIONES Y NUEVAS LÍNEAS DE INVESTIGACIÓN

5.1. INTRODUCCIÓN

Se ha demostrado que el funcionamiento efectivo de los sistemas de monitorización de la salud estructural (*SHM*) necesita una absoluta integración de los mismos 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, la valoración de los costes de mantenimiento y reparación que pudieran necesitarse o su eficiencia a lo largo del tiempo.

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 en el ámbito de la monitorización. 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.

Por lo tanto, el objetivo general que persigue este proyecto es ampliar la visión de las infraestructuras civiles para que sean concebidas no solo como elementos de comunicación físicos sino también como partes fundamentales del sistema de comunicación de información global, que facilitan la integración e interrelación humana gracias a una instrumentación eficiente.

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.

5.2. CONCLUSIONES

5.2.1. 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.

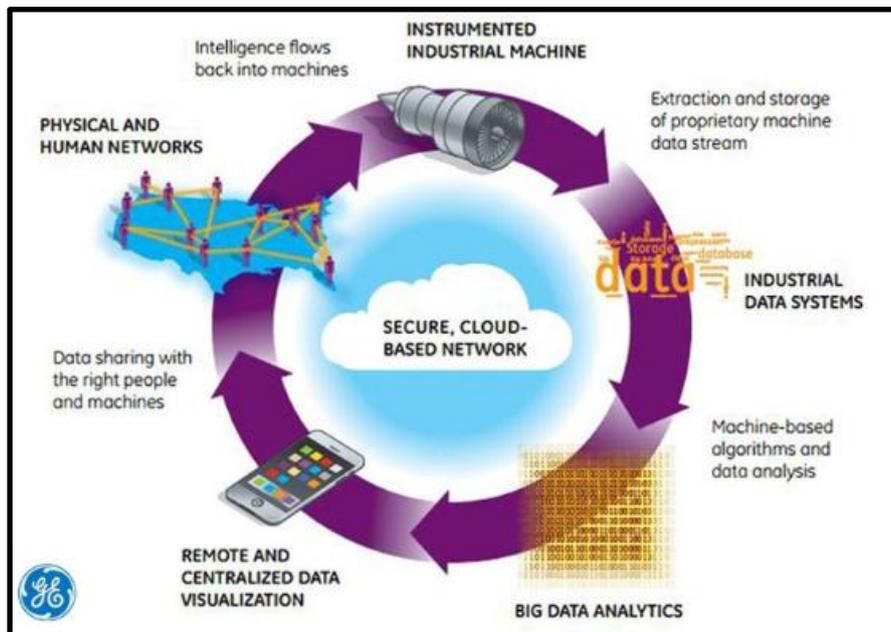


Figura 33 Modelo circular para el aprovechamiento óptimo de los datos

En resumen, se trata de aplicar el concepto de economía circular, basado en la eliminación del elemento residual o inútil mediante una readaptación constante y flexible, al terreno de las telecomunicaciones, para generar un entorno social colaborativo sin barreras físicas, tecnológicas ni cognitivas.

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.

5.2.2. 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, 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. Además, la creciente disponibilidad de grandes cantidades de datos proporciona robustez a los modelos estadísticos, por lo que en el mundo actual parece que estas técnicas están cobrando relevancia sobre la denominada “modelización inversa”, que consiste en diseñar un modelo computacional complejo que se ajuste a las mediciones reales proporcionadas por los sensores.

5.2.3. Conclusiones sobre el postproceso de los datos

Las técnicas de procesamiento de datos para obtener información relativa al estado estructural, como el Análisis de Componentes Principales, permiten simplificar mucho los datos conservando la información sensible al daño. El PCA es un algoritmo estadístico para datos multivariados que se emplea para la normalización de datos, pero también para caracterizar o distinguir los efectos derivados de factores ambientales y operativos sin necesidad de medirlos. El objetivo de este proceso de normalización y proyección de los datos es eliminar cualquier tendencia relacionada con acciones conocidas que afecten a los datos de las series temporales y eliminar redundancias en la información analizada.

Si bien la representación de los componentes principales proporciona una visión cualitativa del estado estructural, el PCA permite el cálculo de unos indicadores de daño cuya función es aportar una valoración cuantitativa que caracterice las condiciones de funcionamiento de la estructura y permita detectar anomalías. Estos indicadores han demostrado ser capaces de fusionar la información procedente de todos los sensores del sistema de instrumentación de una estructura en un único valor representativo, facilitando una evaluación a nivel de conjunto que ayuda considerablemente en la toma de decisiones.

Por su parte, las funciones de distribución de densidad de kernel permiten abordar la realización de modelos estadísticos continuos que se adapten a la distribución real de los datos de forma flexible. Estas funciones permiten caracterizar el comportamiento estadístico de los indicadores de daño correspondientes a un determinado nivel de funcionamiento de la estructura, así como establecer los límites de aceptación entre los distintos estados posibles en base a esa información. En definitiva, las funciones kernel son muy útiles para trabajar con variables continuas cuya distribución de probabilidad pueda no adaptarse siempre a una determinada función conocida.

5.2.4. Conclusiones sobre la herramienta de detección de daños

Tecnificación y objetivación de la evaluación del estado estructural

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. Si se confirma que la estructura está funcionando adecuadamente, el siguiente paso consiste en actualizar el modelo con la nueva información registrada de forma que represente la situación real actual de la estructura. De este modo, se podría evaluar el efecto de las acciones de mantenimiento y reparación, o simplemente ajustar el modelo de referencia a la situación real de envejecimiento o deterioro que presente la estructura con el paso del tiempo.

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.

Contribución al enfoque multi-escala de los Sistemas de Gestión de Puentes

La metodología presentada en este trabajo pretende aportar una visión integradora a todos los niveles de la gestión de puentes, donde la información primaria procedente de la instrumentación se convierta en decisiva para la toma de decisiones a nivel de red de infraestructuras. En la siguiente figura se muestra de forma gráfica esta visión global.

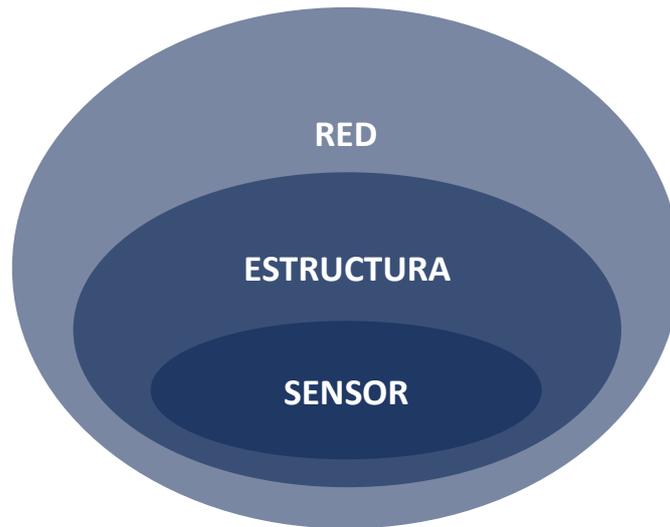


Figura 34 Representación del concepto multi-escala en la Monitorización Estructural

Esta representación muestra claramente que no se puede prescindir de la información proporcionada por el dato medido a nivel de sensor, ya que su repercusión puede ser muy elevada a nivel de red si se aplican las herramientas de análisis y procesamiento de datos adecuadas. De forma general, si se dispone de una red formada por n estructuras, y cada una de ellas dispone de un sistema de instrumentación compuesto por m sensores, se tendrá el siguiente planteamiento:

1. **Nivel de sensor**: La función de autocorrelación permite comprender la serie de datos y filtrar las causas especiales existentes. Una vez filtrados, los datos podrán ser evaluados mediante Diagramas de Control de Calidad que aseguren que la estructura se encuentra bajo control y proceder hacia los estudios correspondientes a nivel de puente o estructura.
2. **Nivel de estructura**: en este nivel se realizarían los modelos estadísticos (o analíticos) que proporcionen información directamente relacionada con la presencia de daños en la estructura, y doten al sistema de una valoración cuantitativa que fortalezca las inspecciones visuales. Esto aportará una visión general del estado de la estructura que facilitará la gestión a nivel de red.

3. **Nivel de Red:** a la hora de gestionar la red de estructuras y optimizar los recursos mediante la simulación de diferentes tácticas de mantenimiento y gestión, se podrá desarrollar un modelo de cadenas de Markov que utilice la información recibida del nivel de estructura para plantear y evaluar de forma detallada las distintas posibilidades de actuación, aportando un soporte objetivo de cara a la toma de decisiones.

5.3. NUEVAS LÍNEAS DE INVESTIGACIÓN

5.3.1. Líneas de investigación sobre la instrumentación

- El contexto tecnológico actual ha permitido el desarrollo de potentes sistemas de instrumentación capaces de proporcionar grandes volúmenes de datos de forma prácticamente constante. El control directo de toda esta información, así como su aprovechamiento para contribuir a tomar decisiones fundamentadas de forma objetiva, se ha convertido en el principal reto de los propietarios de las redes de estructuras, que buscan dotar de inteligencia a sus sistemas de gestión.

En esta línea, y dada la influencia de las estructuras en la sociedad, se propone la posibilidad de acceder a los datos generados directamente por los usuarios de las mismas, bien desde sus dispositivos móviles o desde sus vehículos como nueva fuente de alimentación de una base de datos sobre la que valorar la importancia de cada estructura dentro de la red y adquirir al mismo tiempo información sobre su estado de servicio en base al criterio de los propios usuarios.

- Si bien este trabajo se ha centrado en el análisis y procesamiento de datos de carácter estático, se plantea la importancia de los datos dinámicos, como las aceleraciones.

El comportamiento dinámico es una de las principales formas de evaluar la presencia de anomalías estructurales, ya que las frecuencias naturales son parámetros característicos sensibles al daño que pueden aportar información útil sobre la estructura. En esta línea se propone la implementación de sistemas de

alarmas que analicen de forma autónoma los datos dinámicos, controlando las frecuencias naturales de vibración de la estructura independientemente de la fase de construcción u operación en la que se encuentren o analizando la amplificación dinámica real en función de la relación con la frecuencia resonante.

En este mismo marco, se propone el estudio de la transmisión de vibraciones entre estructura y subestructura con el fin de analizar, mediante correlaciones cruzadas, el concepto de la fuga de vibraciones.

5.3.2. Líneas de investigación sobre el sistema de SHM

- La herramienta diseñada en este proyecto ha sido validada mediante la generación de datos sintéticos por simulación computacional. Estos datos constituyen una reproducción de los datos originales, al presentar el mismo comportamiento estadístico y correlaciones para asegurar que se conoce el estado al que pertenecen y poder así calcular el nivel de falsos diagnósticos de la herramienta. Sin embargo, lo ideal sería disponer de datos correspondientes a otra fase de monitorización real que permitieran calificar el potencial de la herramienta de forma más fiable.

La configuración de un modelo a escala que represente la estructura a controlar permite disponer de un sistema de ensayo que proporcione datos ante cualquier excitación conocida, facilitando la validación de la herramienta. Este enfoque permite además disponer de datos correspondientes a posibles daños en la estructura, sin necesidad de realizar alteraciones costosas en la estructura real o de esperar a que se produzcan los deterioros.

Por lo tanto, se plantea como posible línea de investigación futura la evaluación de datos procedentes de un modelo a escala representativo de la estructura a analizar que permitan valorar de forma fiable la calidad de la herramienta y avanzar en la caracterización de los distintos estados posibles de la estructura mediante técnicas sofisticadas de aprendizaje supervisado.

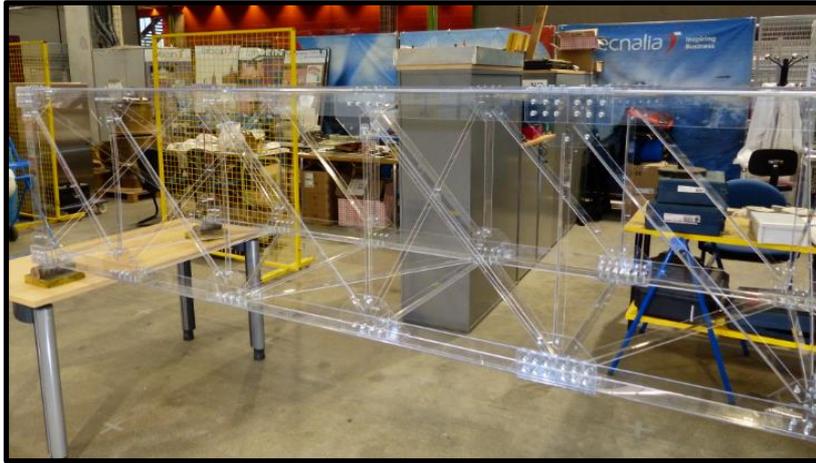


Figura 35 Modelo a escala de un puente de celosía (Cortesía de Tecnalia)

- En cuanto a la técnica empleada para el desarrollo de la herramienta, basada en la generación de modelos estadísticos de los parámetros de interés mediante el cálculo de la función de densidad de kernel, se propone como práctica de gran utilidad la optimización de los parámetros de estimación de kernel: el tamaño de la muestra y el ancho de banda h , con la idea de mejorar el ajuste de la distribución a la población real e incrementar así la precisión de los modelos.
- Por otro lado, en una búsqueda de proporcionar a la herramienta una mayor fiabilidad, se plantea el interés por analizar los datos anómalos o indicativos de daño, es decir, aquellos que exceden el límite preestablecido por la herramienta. De este modo, si se realiza un primer análisis de los datos correspondientes a falsas alarmas (es decir: todos aquellos datos que, procediendo del estado no dañado de la estructura proporcionen un indicador superior al límite), se podrán caracterizar estadísticamente estos indicadores, permitiendo distinguirlos de aquellos indicadores que procedan de la presencia de algún daño real en la estructura.

Estos datos tendrían que analizarse según las teorías de valores extremos para encontrar una distribución representativa de los datos anómalos derivados de las condiciones ambientales y operativas que permita diferenciarlos de los indicadores reales de daño. Si se dispusiera del modelo a escala de estudio planteado en la propuesta anterior, también se podrían analizar estadísticamente los indicadores anómalos procedentes de cada una de las distintas situaciones de daño inducidas en este sistema, contribuyendo a la clasificación de los indicadores de anomalías.

- Finalmente, en este mismo contexto, se propone el empleo de la función de autocorrelación sobre la serie de datos actualizada tras las nuevas inspecciones para detectar posibles relaciones entre los datos registrados, indicando la presencia de algún tipo de anomalía o causa especial en el comportamiento, que deba ser analizada previamente al tratamiento mediante el PCA.

5.3.3. Líneas de investigación en el ámbito de la gestión

- La herramienta de detección de anomalías mediante la información proporcionada por un indicador de daño puede aportar una importante contribución para la toma de decisiones de gestión, si se ponderan los indicadores de cada estructura de la red mediante factores que tengan en cuenta aspectos de funcionalidad, disponibilidad, fiabilidad y seguridad, para alcanzar una gestión adecuada de las redes de estructuras. Este planteamiento deriva de la metodología de evaluación estructural conocida como *RAMS* (Reliability, Availability, Maintenance and Serviceability), que hace referencia a los términos fundamentales de cualquier proceso y está actualmente en fase de implantación en el ámbito de la ingeniería civil.

Mediante un sistema robusto de *SHM* como el planteado en este trabajo, se podrán definir de forma bien fundamentada las alternativas de reparación, así como su valoración en términos de coste, magnitud de los daños alcanzables y circunstancias de accesibilidad para la operación, facilitando la elaboración de programas de actuación adaptados a los presupuestos disponibles que cumplan de forma óptima con los planteamientos integradores de la metodología *RAMS*.

- Por su parte, la predicción del estado futuro de los puentes constituye actualmente un reto muy importante en la ingeniería civil. Se plantea la utilización de los denominados modelos de deterioro para abordar este enfoque de análisis de la evolución del estado estructural en el tiempo, que permita dotar al sistema de *SHM* de la capacidad de anticiparse a posibles fallos y de actuar en consecuencia a la condición actualizada de funcionamiento de las estructuras.

Los modelos de deterioro pueden clasificarse en dos grandes grupos: deterministas y probabilísticos. En los modelos probabilísticos, el estado futuro de la estructura se estima como una función de probabilidad del conjunto de todos los posibles estados que podrían presentarse. Se pueden utilizar dos tipos:

- Función continua: expresa la probabilidad de que un índice de estado sea mayor que el valor dado en relación a la edad del puente. Se conoce como función de supervivencia.
- Función discreta o markoviana: esta metodología se basa en el concepto de las cadenas de Markov, y básicamente divide el espacio de todas las posibles condiciones de la estructura en una serie de estados discretos que analizar y evaluar probabilísticamente.

Por lo tanto, se contemplaría entonces como futura línea de investigación la integración de los indicadores de daño en el procedimiento general de las cadenas de Markov para la definición de un rango finito de escenarios posibles generados mediante Monte Carlo que permitan predecir el estado futuro de la estructura en función de las distintas variables implicadas y facilitar así la anticipación a posibles fallos o deterioros.

ANEXO I

DISEÑO COMPUTACIONAL DE LA HERRAMIENTA

A continuación, se presenta el código empleado para la configuración de la herramienta de detección de daños. El planteamiento presentado se extrajo de los códigos elaborados en “R” aunque puede convertirse directamente a Python u otros lenguajes de programación, lo que le proporciona una gran versatilidad y flexibilidad para adaptarse de forma sencilla a cualquier entorno de trabajo. El primer “script” contiene el código necesario para configurar la herramienta a partir de los datos procedentes de la monitorización en el estado de referencia, y por tanto incluye la obtención de los componentes principales, el cálculo de los indicadores de daño, el establecimiento de los límites de aceptación y la validación del algoritmo mediante una muestra generada sintéticamente por simulación.

El siguiente código muestra las funciones necesarias para la integración de la herramienta en el sistema de *SHM*. La primera de ellas (“detection”) realiza la evaluación de los datos registrados en un nuevo proceso de monitorización y devuelve los indicadores de daño correspondientes. La segunda función se encarga de actualizar los límites de aceptación de la herramienta en base a la muestra de referencia actualizada con los nuevos datos correspondientes a la situación normal de funcionamiento.

Por último, se presente una consola de trabajo en la que se recibirían los nuevos datos y se realizarían las llamadas a las funciones para a continuación representar de forma gráfica la evolución del índice combinado en el tiempo, o el modelo estadístico de los últimos datos registrados para poder acumular la información comprobar de forma constante el comportamiento de la estructura en base a algún nivel o porcentaje de alarmas establecido previamente.

SCRIPT 1: Configuración de la herramienta

#1- INICIALIZACIÓN

#Cargar paquetes

```
install.packages("random"); install.packages("ks");
install.packages("kdensity"); install.packages("corrplot");
install.packages("psych");
install.packages("PerformanceAnalytics");
install.packages("readxl")
```

#Leer paquetes

```
library("random"); library("ks"); library("kdensity");
library("corrplot"); library("psych");
library("PerformanceAnalytics"); library("readxl")
```

2- LECTURA DE LOS DATOS DE REFERENCIA

#Forma genérica importación de Excel:

```
Xdata <- read_excel("Desktop/TECNALIA/TRABAJO FIN DE
MASTER/3_METODOLOGÍA/Trabajo en R/Xdata.xlsx", sheet = "DATOS
SENSORES") View(Xdata)
Xdata=as.matrix(Xdata)
```

#Representación de Los datos

```
CR=cor(Xdata)
corrplot(CR)
chart.Correlation(Xdata)
```

#Tamaño series de datos

```
N=268;
```

#3-CÁLCULO DEL PCA MANUAL Y OBTENCIÓN DE LOS INDICADORES

#Normalización de Los datos (Xdata se normaliza a Xnorm)

```
meanx=sapply(Xdata,mean) desvx=sapply(Xdata,sd);
Xnorm=matrix(0,nrow=N,ncol=ncol(Xdata));
for (i in 1:N) {
Xnorm[i,]=(as.matrix(Xdata[i,])-meanx)/desvx
}
```

#Determinación de Los componentes principales

```
Xcov=cov(Xnorm);
Eig=eigen(Xcov);
P=Eig$vector;
```

```

#Reducción del modelo P -> Pr seleccionando cantidad de componentes
principales (r):
PCA=prcomp(Xdata,scale=TRUE);
summary(PCA)
plot(PCA)
r=2
Pr=P[,1:r];

#Cálculo de Los índices de daño (Q, T2 Y M)
Qst=numeric(N);
T2s=numeric(N);
Mst=numeric(N);

#Obtención de Las matrices auxiliares para cálculo de Los índices de
daño
A=diag(Eig$values);
Ainv=solve(A);
Air=Ainv[1:r, 1:r]
MI=diag(1,nrow=ncol(Xdata),ncol=ncol(Xdata));
Mq=MI-(Pr%%t(Pr));
Mt2=(Pr%%Air%%t(Pr));

#Determinación de Los índices de daño para todas Las mediciones de
La muestra de referencia
#INDICE Q-statistic
for (i in 1:N){
  Qst[i]=t(as.matrix(Xnorm[i,]))%%Mq%%as.matrix(Xnorm[i,]);
}

#Función de densidad de probabilidad del índice Q para La muestra de
REFERENCIA (Patrón)
hist(Qst,freq=FALSE, col="lightgreen");
Qdens=kdensity(Qst)
lines(density(Qst),col="red",lwd=3)
plot(density(Qst), col="blue",lwd=5)
#INDICE T^2-statistic
for (i in 1:N){
  T2s[i]=t(as.matrix(Xnorm[i,]))%%Mt2%%as.matrix(Xnorm[i,])
}
#Función de densidad de probabilidad del índice T^2 para La muestra
de REFERENCIA
hist(T2s,freq=FALSE, col="orange");
t2dens=kdensity(T2s)
lines(density(T2s),col="red",lwd=3)
plot(density(T2s),col="blue",lwd=3)

#Definición del índice global o combinado (m-statistic)
Mst=(T2s+Qst)

```

```

Mdens=kdensity(Mst)
densM=kde(Mst);
#Cálculo del límite de aceptación para un nivel de confianza del 95%
(nivel incertidumbre=5%)
LM=qkde(0.95,densM);
plot(density(Mst,0.42),col="blue",lwd=3)
#Para el indicador Qst:
densq=kde(Qst);
LQ=qkde(0.95,densq)
#Para el indicador T2st
denst=kde(T2s)
LT2=qkde(0.95,denst);

#Representación gráfica del modelo estadístico del ÍNDICE M
plot(density(Mst), col="black",lwd=2)
cordmx1=c(-0.75,seq(-0.75,LM,0.001),LM);
cordmy1=c(0,Mdens(seq(-0.75,LM,0.001)),0);
  polygon(cordmx1,cordmy1,col="lightgreen")
cordmx2=c(LM,seq(LM,8,0.001),8);
  cordmy2=c(0,Mdens(seq(LM,8,0.001)),0)
  polygon(cordmx2,cordmy2,col="red")

#4-VALIDACIÓN: GENERACIÓN DE NUEVOS PUNTOS PARA VALIDAR LA HERRAMIENTA

#Registro de los datos y establecimiento de límites de muestreo
TH1=Xdata[,1]; TH3=Xdata[,2]; TH4=Xdata[,3]; TH8=Xdata[,4];
M1=mean(TH1); S1=sd(TH1); VL1=M1-2S1; VH1=M1+2S1;
M3=mean(TH3); S3=sd(TH3); VL3=M3-2S3; VH3=M3+2S3;
M4=mean(TH4); S4=sd(TH4); VL4=M4-2S4; VH4=M4+2S4;
M8=mean(TH8); S8=sd(TH8); VL8=M8-2S8; VH8=M8+2S8;

#Obtención de los modelos de regresión lineal (correlaciones de referencia)
lm13=lm(TH3~TH1); coef13=t(coefficients(lm13)); A13=coef13[1,1];
  B13=coef13[1,2]; SD13=S3;
lm14=lm(TH4~TH1); coef14=t(coefficients(lm14)); A14=coef14[1,1];
  B14=coef14[1,2]; SD14=S4;
lm18=lm(TH8~TH1); coef18=t(coefficients(lm18)); A18=coef18[1,1];
  B18=coef18[1,2]; SD18=S8;

#Generación de n datos "X" mediante muestreo aleatorio de la función kernel de TH1
#Inicialización muestreo
n=10000;
GENX=numeric(n); GENY=numeric(n); DFX=numeric(n); DF3=numeric(n);
  DF4=numeric(n); DF8=numeric(n); X=TH1; Y=TH3;
#Función densidad de Kernel para el sensor TH1

```

```

bw1=0.5;
phat1=kde(x=X,bw1)
#A partir de Los n valores de THL1 se emplean Las rectas de
  regresión para generar Los datos de Los demás sensores
for (i in 1:n){
repeat{ GENX[i]=rkde(1,phat1);#muestreo aleatorio para el sensor
  THL1 if (VL1<GENX[i]&&GENX[i]<VH1){
    DFX[i]=GENX[i]
    DF3[i]=(A13+B13*DFX[i])+rnorm(1,0,SD13)
    DF4[i]=(A14+B14*DFX[i])+rnorm(1,0,SD14)
    DF8[i]=(A18+B18*DFX[i])+rnorm(1,0,SD18)
    break
  }
}
}
#registro de Los datos generados
D1=as.data.frame(DFX);
D3=as.data.frame(DF3);
D4=as.data.frame(DF4);
D8=as.data.frame(DF8);

#Generación de La matriz de datos nuevos (de Validación)
Ydata=cbind(D1,D3,D4,D8)
CrY=cor(Ydata)
chart.Correlation(Ydata)

#Normalización de La matriz de datos de validación
Yvalnorm=matrix(0,nrow=n,ncol=ncol(Ydata));
for (i in 1:n) {
  Yvalnorm[i,]=(as.matrix(Ydata[i,])-meanx)/desvx
}

#Evaluación de La muestra de validación mediante Los indicadores de
  daño
Qnew=numeric(n);
T2new=numeric(n);
for(i in 1:n){
Qnew[i]=t(as.matrix(Yvalnorm[i,]))**%Mq**as.matrix(Yvalnorm[i,]);
T2new[i]=t(as.matrix(Yvalnorm[i,]))**%Mt2**as.matrix(Yvalnorm[i,])}
Mnew = (Qnew+T2new);

#Comparación de Los modelos o patrones de referencia y validación
plot(density(Mnew),col="orange",lwd=5);
lines(density(Mst),col="blue",lwd=5)

#Cálculo de Los ratios de falsa alarma (comprobación cuantitativa)
FAILM=length(which(Mnew>LM));
RFAm=(FAILM/n)*100

```

SCRIPT 2: FUNCIÓN DE EVALUACIÓN (detection_function.R)

```
detection = function(d){ #Función de detección de anomalías a partir  
de los indicadores  
  #1-INICIALIZACIÓN  
  dn=matrix(0,nrow=nrow(d),ncol=4)  
  T2sn=numeric(nrow(d));  
  Qsn=numeric(nrow(d));  
  Msn=numeric(nrow(d));  
  DMG=logical(nrow(d));  
  
  #Normalización de los datos registrados  
  for (i in 1:nrow(d)) {  
    dn[i,]=(as.matrix(d[i,])-meanx)/desvx  
  }  
  
  #2-CÁLCULO DE LOS INDICADORES DE DAÑO  
  for(i in 1:nrow(d)){  
    T2sn[i]=t(as.matrix(dn[i,]))%%Mt2%%as.matrix(dn[i,]);  
    Qsn[i]=t(as.matrix(dn[i,]))%%Mq%%as.matrix(dn[i,]);  
    Msn[i]=(T2sn[i]+Qsn[i]);  
    #evaluación del indicador respecto al límite  
    if (Msn[i]>LM){  
      DMG[i]=TRUE  
    }  
  }  
  
  return(list(Msn=Msn,T2sn=T2sn,Qsn=Qsn,DAMAGE=DMG))  
}
```

SCRIPT 3: FUNCIÓN DE ACTUALIZACIÓN (PCA_UPDATE_function.R)

```

PCA_update= function (Xup) { #Aplicación del PCA para los nuevos
datos actualizados
#1-LECTURA DE LOS DATOS DE REFERENCIA (MUESTRA
ACTUALIZADA)
N=nrow(Xup);

#2-CALCULO DEL PCA MANUAL Y OBTENCIÓN INDICADORES
#normalización de los datos
meanx=sapply(Xup,mean)
desvx=sapply(Xup,sd);
Xup_n=matrix(0,nrow=N,ncol=ncol(Xup));
for (i in 1:N) {
  Xup_n[i,]=(as.matrix(Xup[i,])-meanx)/desvx
}

#3-DETERMINACIÓN DE LOS COMPONENTES PRINCIPALES
Xcov=cov(Xup_n);
Eig=eigen(Xcov);
P=Eig$vectors;
#Reducción del modelo P -->Pr seleccionando cuántos componentes
principales se van a emplear (r)
r=2
Pr=P[,1:r];

#4-CALCULO DE LOS ÍNDICES DE DAÑO Q, T2 Y M
Qst=numeric(N);
T2s=numeric(N);
Mst=numeric(N);

#Obtención de las matrices auxiliares para cálculo de los índices
de daño
A=diag(Eig$values);
Ainv=solve(A);
Air=Ainv[1:r,1:r]
MI=diag(1,nrow=ncol(Xup),ncol=ncol(Xup));
Mq=MI-(Pr%*%t(Pr));
Mt2=(Pr%*%Air%*%t(Pr));

#Determinación de los índices de daño para todas las mediciones
#Índice Q-statistic
for (i in 1:N){
  Qst[i]=t(as.matrix(Xup_n[i,]))%*%Mq%*%as.matrix(Xup_n[i,]);
}
#Función de densidad de probabilidad del índice Q para la muestra

```

```

de REFERENCIA (Patrón)
Qdens=kdensity(Qst)
#INDICE T^2-statistic
for (i in 1:N){
T2s[i]=t(as.matrix(Xup_n[i,]))**Mt2**as.matrix(Xup_n[i,])
}
#Función de densidad de probabilidad del índice T^2 para la
muestra de REFERENCIA
t2dens=kdensity(T2s)

#Definición del índice global (o combinado) y límite de
aceptación
Mst=(T2s+Qst)
Mdens=kdensity(Mst)
densM=kde(Mst);
#Límite de aceptación para un nivel de confianza del 95%
LM=qkde(0.95,densM);
PcM=Mdens(LM) #Evalúa la probabilidad crítica correspondiente

#Límites para los indicadores secundarios
#Indicador Qst:
densq=kde(Qst);
LQ=qkde(0.95,densq)
#Indicador T2st
denst=kde(T2s)
LT2=qkde(0.95,denst);
return(list(Mst=Mst,T2s=T2s,LQ=LQ,LT2=LT2,LM=LM,meanx=meanx,desvx
=desvx,Mq=Mq,Mt2=Mt2))
}

```

SCRIPT 4: CONSOLA DE TRABAJO

#1-INICIALIZACIÓN

```

XXdat=Xdata; #Vector para almacenar nuevos datos
PCAm=PCA_update(Xdata) #Primer modelo de referencia
Tmodel=0.6524459; #Inicialización del índice T
Qmodel=0.4594943; #Inicialización del índice Q
Mmodel=(Tmodel[1]+Qmodel[1]);

```

#2-LECTURA DE NUEVO REGISTRO DE DATOS

```

Wdata= read.table("clipboard")

```

#3-EVALUACIÓN DE DATOS MEDIANTE FUNCION DETECCIÓN

```

dtt=detection(Wdata)
#Extracción de los resultados de la función (indicadores de daño y alarma)
DIT=dtT$T2sn;
DIQ=dtT$Qsn;
DIM=dtT$Msn;
dmg=dtT$DAMAGE;

```

#4-ACUMULACION DATOS (se almacenan los nuevos indicadores)

```

for (i in (1:length(DIM))) {
  Tmodel[length(Tmodel)+1]=DIT[i] #acumula los indicadores T
  Qmodel[length(Qmodel)+1]=DIQ[i] #acumula los indicadores Q
  Mmodel[length(Mmodel)+1]=DIM[i] #acumula los indicadores M
}

```

#5-CREACIÓN DE GRÁFICO TEMPORAL

#Inicialización

```

seg=plot(c(0,length(Mmodel)),c(0,max(Mmodel,LM)+1),main="GRÁFICO M-
index",col="white")
abline(LM,0,col="blue",lwd=2)

```

#Representación

```

for (i in 1:length(Mmodel)) {
  if(Mmodel[i]>LM & Tmodel[i]>LT2 & Qmodel[i]>LQ){
    points(i,Mmodel[i],col="red",pch=15)
  }
  else if (Mmodel[i]>LM | (Mmodel[i]>LM & Qmodel[i]>LQ) |
(Mmodel[i]>LM & Qmodel[i]>LQ)){
    points(i,Mmodel[i],col="orange",pch=21,bg="pink")
  }
  else {
    points(i,Mmodel[i],col="green",pch=20)
  }
}

```

```

    }
  }
}
#6-COMPARACIÓN DE MODELOS ESTADÍSTICOS
DMnew=density(DIM)
plot(DMnew,col="orange",lwd=3)
lines(density(Mst),col="blue",lwd=3)
#Si Los modelos coinciden --> se actualiza el modelo añadiendo Los datos

#COMPROBACIÓN NUMÉRICA
#Indicador de alarma en función de cierto nivel (%) de indicadores de daño que exceden el límite
lim=15 #este % de datos anómalos indica que el estado actual no corresponde a la referencia
WNG=(length(which(Mmodel>LM)))/length(Mmodel)*100;
if(WNG>lim){print("POSSIBLE DAMAGE")}
else {
  print("CORRECT BEHAVIOUR")}
}

#7-ACTUALIZACION DEL MODELO DE REFERENCIA
#En caso de verificarse el adecuado comportamiento)
#Acumulación de los datos registrados
for (i in (1:length(DIM))){
  XXdat[nrow(XXdat)+1,]=Wdata[i,]
  Xdt[nrow(Xdt)+1,]=Wdata[i,]
}

#Actualización del modelo con todos los datos
PCAm=PCA_update(XXdat) #función de actualización

#Extracción de los resultados de la función
meanx=PCAm$meanx;
desvx=PCAm$desvx;
LQ=PCAm$LQ;
LT2=PCAm$LT2;
LM=PCAm$LM;
Mq=PCAm$Mq;
Mt2=PCAm$Mt2;
Mst=PCAm$Mst; #nueva muestra de referencia de indicadores M
COR2=cor(XXdat) #Actualización de la matriz de Correlaciones

```

ANEXO II

DIAGRAMAS DE FLUJO

En este anexo se presentan los diagramas de flujo generales para la configuración de una herramienta de detección de anomalías a partir del Análisis de Componentes Principales integrado en la metodología del reconocimiento de patrones estadísticos para resolver un problema de clasificación entre dos estados posibles: dañado y no dañado.

Cabe destacar que esta técnica sería aplicable a clasificaciones más complejas si se dispusiera de datos correspondientes a otros posibles estados de funcionamiento de la estructura. Mediante estos diagramas se pretende justificar el carácter sistemático y flexible de las metodologías basadas en datos, donde se puede adoptar un mismo proceso independientemente de la complejidad del sistema estructural analizado.

- El primer diagrama de flujo representa el procedimiento necesario para la configuración inicial de la herramienta a partir de unos datos existentes procedentes de un sistema de instrumentación.
- El segundo diagrama muestra la puesta en práctica del instrumento una vez integrado en el sistema de *SHM*, describiendo el proceso de toma de decisión sobre el estado de la estructura y el almacenamiento de los nuevos datos registrados.

CONFIGURACIÓN DE LA HERRAMIENTA DE DETECCIÓN DE ANOMALÍAS

INSTRUMENTACIÓN

SENSORES

Datos Multivariados

PREPROCESAMIENTO

- Depuración
- Filtrado
- Función de Autocorrelación
- Diagramas de Control

¿DATOS CONTROLADOS?

NO

SI

PCA PARA LA DETECCIÓN DE ANOMALÍAS

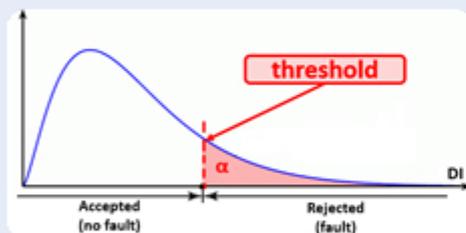
DISEÑO

MODELO DE REFERENCIA

- ANÁLISIS DE COMPONENTES PRINCIPALES
- CÁLCULO DE LOS INDICADORES DE DAÑO
- DEFINICIÓN DE LA FUNCIÓN KERNEL

LÍMITES DE DECISIÓN

- ESTABLECIMIENTO NIVEL DE CONFIANZA
- CÁLCULO DEL LÍMITE DE ACEPTACIÓN



VALIDACIÓN

MODELO VALIDACIÓN

- GENERACIÓN DE DATOS SINTÉTICOS
- CÁLCULO DE INDICADORES DE DAÑO
- DEFINICIÓN DE LA FUNCIÓN KERNEL

EVALUACIÓN

- SUPERPOSICIÓN DE MODELOS
- RATIO DE FALSAS ALARMAS

$$RFA = \frac{\text{Número falsas alarmas}}{\text{Tamaño muestra}}$$

¿RFA < alpha?

NO

REVISIÓN DEL PROCESO

SI

101

IMPLEMENTACIÓN

IMPLEMENTACIÓN DE LA HERRAMIENTA EN EL SISTEMA DE SHM

REACTIVACIÓN DEL SISTEMA DE INSTRUMENTACIÓN

SENSORES

Nuevos Datos

CÁLCULO DE INDICADORES ID_{θ}

$$T_i^2 = x_{ni} P \Lambda^{-1} P^T x_{ni}^T$$
$$Q_i = x_{ni} (I - P \cdot P^T) x_{ni}^T$$
$$\theta = T^2 + Q$$

EVALUACIÓN DE LOS INDICADORES DE DAÑO

ANÁLISIS DE RESULTADOS

- EVOLUCIÓN DEL COMPORTAMIENTO
- DETECCIÓN DE TENDENCIAS
- NIVEL (%) INDICADORES > LÍMITE

¿EXISTEN
ANOMALÍAS?

NO

ACTUALIZACIÓN DEL MODELO
DE REFERENCIA

SI

**ALERTA DE
DAÑO**

LISTA DE FIGURAS

<i>Figura 1 Analogía entre el control médico y el control estructural</i>	7
<i>Figura 2 (a) Inclusiones en los bordes de grano en U-6Nb. (b) Propagación de grieta a lo largo de las líneas de inclusión tras una carga de choque</i>	10
<i>Figura 4 Deslizamiento de talud del puente</i>	11
<i>Figura 3 Grieta horizontal en mitad de estribo</i>	11
<i>Figura 5 Corrosión y deterioro de apoyo balancín de acero</i>	12
<i>Figura 6 Reducción de la sección de viga por corrosión e impacto</i>	12
<i>Figura 7 Organigrama del desarrollo de un sistema de Monitorización Estructural</i>	21
<i>Figura 8 Ejemplo de emplazamiento de sensores</i>	25
<i>Figura 9 Galga de esfuerzo de hilo vibratorio</i>	25
<i>Figura 10 Esquema general del procesamiento de señales</i>	27
<i>Figura 11 Análisis de Componentes Principales</i>	35
<i>Figura 12 Composición de una función kernel gaussiana</i>	42
<i>Figura 13 Delimitación de estado sobre el modelo de referencia</i>	44
<i>Figura 14 Modelo de regresión lineal</i>	48
<i>Figura 15 Implementación de la herramienta de detección de daños en el sistema de SHM</i>	50
<i>Figura 16 Vano central y pila nº 4 del puente Beltrán (Cortesía de INECO; extraído de [T.4]).</i>	54
<i>Figura 17 Detalle de un anclaje de fibra óptica y caja de conexiones en tablero (Cortesía de Ineco; extraído de [T.4]).</i>	57
<i>Figura 18 Esquema de instrumentación del puente Beltrán (Cortesía de Ineco; extraído de [T.4]).</i>	58

Figura 19 Filtrado de la componente cíclica debida a la temperatura en la serie temporal anual (Extraído de [T.4])..... 60

Figura 20 Diagrama de Control estadístico del valor medio de la serie temporal filtrada (Extraído de [T.4])..... 61

Figura 21 Extracción de los 10 primeros elementos de la muestra de referencia..... 63

Figura 22 Extracción de los 10 primeros elementos de la muestra de referencia normalizada 63

Figura 23 Análisis de Componentes Principales de la muestra de referencia 65

Figura 24 Funciones densidad de los indicadores de daño individuales 68

Figura 25 Función densidad de kernel del indicador combinado 68

Figura 26 Delimitación de los estados de clasificación sobre el modelo de referencia con un 5% de incertidumbre 70

Figura 27 Diagramas de dispersión y correlaciones entre sensores..... 71

Figura 28 Función kernel de las muestras original y de validación. Comparación..... 72

Figura 29 Diagramas de dispersión y correlaciones entre sensores de la muestra de validación 74

Figura 30 Comparación de los modelos estadísticos de referencia y validación 75

Figura 31 Sistema portátil de transmisión de datos..... 78

Figura 32 Evolución temporal del indicador combinado para la detección de comportamientos estructurales anómalos 79

Figura 33 Modelo circular para el aprovechamiento óptimo de los datos 82

Figura 34 Representación del concepto multi-escala en la Monitorización Estructural 86

Figura 35 Modelo a escala de un puente de celosía (Cortesía de Tecnalía)..... 89

BIBLIOGRAFÍA

A continuación, se presentan todas las referencias por orden alfabético. Se han clasificado en tres bloques fundamentales: libros, tesis doctorales y artículos científicos.

LIBROS

[L.1] Charles R. Farrar, Keith Worden: *Structural Health Monitoring*. John Wiley & Sons Ltd. ISBN: 978-1-119-99433-5. 2013.

[L.2] Christian Boller, Fou-Kuo Chang, Yozo Fujino: *Encyclopedia of Structural Health Monitoring*. John Wiley & Sons Ltd. ISBN: 978-0-470-05822-0. 2009.

[L.3] Douglas C. Montgomery, Elizabeth A. Peck, G. Geoffrey Vining. *Introduction to Linear Regression Analysis*. John Wiley & Sons Ltd. ISBN: 978-0-470-54281-1. 2012.

[L.4] D.Huston: *Structural Sensing, Health Monitoring, and Performance Evaluation*. Taylor and Frances Group, LLC. ISBN: 978-750-8400. 2011.

[L.5] George Deodatis, Bruce R. Ellingwood, Dan M. Frangopol. *Safety, Reliability, Risk and Life-Cycle Performance of Structures and Infrastructure*. CRC Press. ISBN: 978-1-138-0086-5. 2013.

[L.6] John D. Kelleher, Brian Mac Namee, Aoife D’Arcy. *Fundamentals of Machine Learning for Predictive Data Analytics*. MIT Press. ISBN: 978-0-262-02944-5. 2015.

[L.7] M. L. Wang, J.P. Lynch and H. Sohn: *Sensor Technologies for Civil Infrastructures; Volume 1: Sensing Hardware and Data Collection Methods for Performance Assessment*. Woodhead Publishing Ltd. ISBN: 978-0-85709-432-2. 2014.

[L.8] M. L. Wang, J.P. Lynch and H. Sohn: *Sensor Technologies for Civil Infrastructures; Volume 2: Applications in Structural Health Monitoring*. Woodhead Publishing Ltd. ISBN: 978-1-78242-242-6. 2014.

[L.9] **Victor (Wai Kin) Chan.** *Theory and Applications of Monte Carlo Simulations.* InTech. ISBN: 978-953-51-1012-5. 2013.

[L.10] **Vistap M. Karbhari, Harhad Ansari:** *Structural Health Monitoring of civil infrastructure systems.* Woodhead Publishing Ltd. ISBN:978-1-84569-392-3. 2009.

[L.11] **William Navidi.** *Estadística para ingenieros y científicos.* McGraw-Hill. ISBN: 970-10-5629-9. 2006.

[L.12] **You-Lin Xu, Yong Xia.** *Structural Health Monitoring of Long-span suspension bridges.* Spon Press. ISBN: 978-0-415-59793-7. 2012.

TESIS DOCTORALES Y PROYECTOS ACADÉMICOS

[T.1] **Ali Oguz Ertekin.** *Probabilistic life cycle cost optimization of bridges.* University of New Jersey. 2013.

[T.2] **Álvaro Gaute Alonso.** *Monitorización de estructuras, criterios de diseño y aplicación a la construcción y verificación del comportamiento de puentes.* Universidad de Cantabria. 2017.

[T.3] **Cláudia Neves.** *Structural Health Monitoring of bridges (Model-free damage detection method using Machine Learning).* Royal Institute of Technology in Stockholm (KTH). 2017

[T.4] **David García Sánchez.** *Control Estadístico y modelos de Regresión lineal. Una forma práctica de control de puentes.* Universidad de Cantabria. 2016.

[T.5] **Ignacio González.** *Application of Monitoring to dynamic characterization and damage detection in bridges.* Royal Institute of Technology in Stockholm (KTH). 2014

[T.6] **João Tiago Martins Neves Pereira.** *Applicability of the SPR paradigm for SHM in bridges.* Universidade Católica Portuguesa. 2012.

[T.7] **Mohammed Abed El-Fatah.** *Bridge Life Cycle Cost optimization (Analysis, evaluation and implementation)*. Royal Institute of Technology in Stockholm (KTH). 2009

[T.8] **Moisés Felipe Mello da Silva.** *Machine Learning algorithms for damage detection in structures under changing normal conditions*. University of Belém (Brazil). 2017.

ARTÍCULOS CIENTÍFICOS Y OTROS DOCUMENTOS

[A.1] **Christian Cremona.** *Big Data and Structural Health Monitoring*. 19th IABSE Congress Stockholm. 2016.

[A.2] **Chang Kook Oh, Hoon Sohn, In-Hwan Bae.** *Statistical novelty detection within the Yeongjong suspension bridge under environmental and operational variations*. IOP Publishing (Smart Materials and Structures). 2009.

[A.3] **David Andrew Clifton, Samuel Hungueny, Lionel Tarassenko.** *Novelty detection with multivariate extreme value statistics*. Springer Science + Business Media, LLC. 2011.

[A.4] **D.A. Tibaduiza, L.E. Mujica, J. Rodellar, A. Güemes.** *Structural damage detection using Principal Component Analysis and damage indices*. Journal of Intelligent Material Systems and Structures. Vol 27. 2016.

[A.5] **D. A. Tibaduiza, M.A. Torres-Arredondo, L.E. Mujica, J. Rodellar, C.P. Fritzen.** *A study of two unsupervised data driven statistical methodologies for detecting and classifying damages in Structural Health Monitoring*. Elsevier (Mechanical Systems and Signal Processing). 2013.

[A.6] **F. Necati Catbas, Melih Susoy, Dan M. Frangopol.** *Structural Health Monitoring and reliability estimation: long span truss bridge application with environmental monitoring data*. Elsevier Ltd. 2008.

- [A.7] **Francesc Pozo, Ignacio Arruga, L.E. Mujica, Magda Ruiz, Elena Podivilova.** *Detection of structural changes through Principal Component Analysis and multivariate statistical inference.* SHM Article (SAGE). 2016.
- [A.8] **Francesc Pozo, Yolanda Vidal.** *Wind turbine fault detection through Principal Component Analysis and Statistical Hypothesis Testing.* Energies Journal. 2016.
- [A.9] **F. Sawo, E. Kempkens.** *Model-based and Statistical approaches for sensor data monitoring for smart bridges.* Federerel Highway Research Institute. Germany. 2018.
- [A.10] **Hui Li, Jinping Ou, Xuefeng Zhao, Wensong Zhou, Hongwei Li, Zhi Zhou.** *Structural Health Monitoring System for the Shandon Binzhou Yellow River Highway Bridge.* Blackwell Publishing. 2006.
- [A.11] **Hoon Sohn, Jerry A. Czarnecki, Charles R. Farrar.** *Structural Health Monitoring using statistical process control.* Journal of Structural Engineering. Vol 126. 2000.
- [A.12] **Haitao Xiao, Cheng Lu, Harutoshi Ogai, Koushik Roy.** *A novel bridge damage diagnosis algorithm based on Statistical Pattern Recognition.* SICE Annual Conference (Hokkaido University). 2014.
- [A.13] **Irwanda Laory, Thanh N. Trinh. Daniele Posenato, Ian F. C. Smith.** *Combined Model-free Data interpretation methodologies for damage detection during continuous monitoring of structures.* Journal of computing in civil engineering. 2013.
- [A.14] **Javier Torres.** *Una visión de las estructuras.* Revista de Obras Públicas (Monográfico Juan José Arenas). 2018.
- [A.15] **João Pedro Santos, Christian Cremona, Paulo Silveira.** *Baseline-free real-time assessment of structural changes.* Taylor and Frances Ltd. (Structure and Infrastructure Engineering). 2015.
- [A.16] **Jaime Vitola, Diego Tibaduiza, Maribel Anaya, Francesc Pozo.** *Structural damage detection and classification based on Machine Learning algorithms.* 8th European Workshop on Structural Health Monitoring (EWSHM). Bilbao 2016.

- [A.17] L.E. Mujica, J. Rodellar, A. Fernández, A. Güemes. *Q-statistic and T^2 -statistic PCA-based measures for damage assessment in structures*. SHM Articles (SAGE). 2010.
- [A.18] L.E. Mujica, J. Vehi, M. Ruiz, M. Verleysen, W. Staszewski, K. Worden. *Multivariate statistics process control for dimensionality reduction in structural assessment*. Elsevier (Mechanical System and Signal Processing 22). 2008.
- [A.19] Markos Markou, Sameer Singh. *Novelty detection: a review. Part 1: statistical approaches*. Elsevier (Signal Processing). 2003.
- [A.20] Meisan Gordan, Hashim Abdul Razak, Zubaidah Ismail, Khaled Ghaedi. *Recent developments in damage identification of structures using Data Mining*. Latin American Journal of Solids and Structures. 2017.
- [A.21] N. Dervilis, K. Worden, E. J. Cross. *On robust regression analysis as a means of exploring environmental and operational conditions for SHM data*. Journal of Sound and Vibration. 2015.
- [A.22] Q. W. Zhang. *Statistical damage identification for bridges using ambient vibration data*. Elsevier Ltd. 2006.
- [A.23] Rubén González, Biao Huang, Eric Lau. *Process Monitoring using kernel density estimation and Bayesian networking with an industrial case study*. ISA Transactions. 2015.
- [A.24] Theanh Nguyen, Tommy H.T. Chan, David P. Thambiratnam. *Controlled Monte Carlo data generation for statistical damage identification employing Mahalanobis squared distance*. SHM (Special Issue Article). 2014.
- [A.25] V.H. Nguyen, J. Mahowald, J.C. Golinval, S. Maas. *Damage detection in civil engineering structure considering temperature effect*. University of Liege, Belgium. 2013.

- [A.26] **William Fawcett, Ignacio Robles, Hannes Krieg, Martin Hughes, Lars Mikalsen, Óscar R. Ramos.** *Cost and environmental evaluation of flexible strategies for highway construction project under traffic growth uncertainty.* ASCE. 2014.
- [A.27] **Wei Lu et al.** *Malfunction diagnosis of sensors based on correlation measurements.* IOP Publishing. 2017.
- [A.28] **You-Liang Ding, Dalei Wu, Guirong Liu, Yaohang Li, Cuilan Gao, Zhongguo John Ma, Weidong Wu.** *Big data-enabled multiscale serviceability analysis for aging bridges.* Elsevier. Digital Communications and Networks. 2016.
- [A.29] **You-Liang Ding, Han-Wei Xhao, Lu Deng, Si-Quin Li, Man-Ya Wang.** *Early warning of abnormal train-induced vibrations for a steel-truss arch railway bridge: case study.* Journal of Bridge Engineering. 2017.
- [A.30] **Yong Xia, Hong Hao.** *Statistical damage identification of structures with frequency changes.* Academic Press (Journal of Sound and Vibration). 2003.
- [A.31] **Zhou Jianting, Yang Yianxi, Wu Diankun.** *A method for analysis Linear Correlation for multi-sensor of Bridge Monitoring System.* ICIS. 2009.
- [A.32] **Ohio Department of Transportation.** *Manual of Bridge Inspection.* 2010.
- [A.33] **BRIME.** *Bridge Management Handbook.* 2001.