

Centro Universitario de la Defensa en la Escuela Naval Militar

TRABAJO FIN DE GRADO

Utilización de cámaras termográficas low cost para la búsqueda automatizada de defectos constructivos mediante técnicas de deep learning

Grado en Ingeniería Mecánica

ALUMNO: Gonzalo Antón Martínez

DIRECTORES: Iván Garrido González

Leticia Pérez Rial

CURSO ACADÉMICO: 2023-2024

Universidade Vigo



Centro Universitario de la Defensa
en la Escuela Naval Militar

TRABAJO FIN DE GRADO

Utilización de cámaras termográficas low cost para la búsqueda automatizada de defectos constructivos mediante técnicas de deep learning

Grado en Ingeniería Mecánica

Intensificación en Tecnología Naval

Cuerpo General

Universidade Vigo

RESUMEN

La prevención y conservación en la construcción son esenciales para cumplir con los objetivos de la Agenda 2030, dada la presencia de posibles defectos constructivos como puentes térmicos, humedades, grietas y filtraciones de aire.

La termografía infrarroja se destaca como una tecnología no destructiva fundamental, ya que su sensibilidad al espectro infrarrojo permite identificar el comportamiento térmicos de los defectos antes de que sean visibles a simple vista. En este trabajo, con el edificio de investigación del CUD-ENM como objeto de estudio, la investigación se centra en el uso de técnicas de *deep learning* (DL) para identificar automáticamente defectos constructivos a partir de imágenes termográficas.

A través de la comparación de los diferentes modos de adquisición de imágenes (activa y pasiva) y de las dos cámaras termográficas (alta gama y *low cost*), se analizan los resultados y limitaciones existentes. El análisis consiste en un modelo de DL de instancias de objetos, proporcionando los resultados que permiten comparar los diferentes métodos de adquisición de imágenes y la evaluación de las limitaciones de las cámaras *low cost*, contribuyendo al desarrollo de sistemas automatizados de detección de defectos constructivos, siendo crucial para mejorar la eficiencia y seguridad en el sector de la construcción.

PALABRAS CLAVE

Defectos constructivos, termografía infrarroja, *deep learning*, inspección automatizada, cámaras *low cost*.

AGRADECIMIENTOS

En primer lugar, quiero agradecer a mis tutores del TFG, Iván Garrido González y Leticia Pérez Rial, por servir como guías en este proyecto y por darme siempre los impulsos necesarios para llevarlo a cabo.

En segundo lugar, agradecer a mis compañeros de promoción, que han sido como mis hermanos durante estos cinco años de Escuela. Siempre han estado en las buenas y en las malas, sin ellos no podría haber llegado hasta aquí.

Por último, agradecer a mi familia y amigos por su confianza en mí y su apoyo siempre. Especialmente a mi madre, que siempre ha creído en mí y lo ha dado todo porque consiga mis objetivos.

CONTENIDO

Contenido 1

Índice de Figuras 3

Índice de Tablas....6

1 Introducción y objetivos....7

1.1 Contexto y motivación....7

1.2 Objetivos....8

1.3 Metodología....9

1.4 Estructura de la memoria....9

2 Estado del arte....11

2.1 Patologías en edificios....11

2.2 La termografía infrarroja....12

2.2.1 Marco teórico de la termografía infrarroja....14

2.2.2 Contexto histórico de la termografía infrarroja....17

2.2.3 La cámara termográfica....18

2.2.4 Modos de trabajo de la termografía infrarroja....19

2.3 Automatización de los resultados termográficos....21

2.3.1 Inteligencia Artificial (IA)....22

2.3.2 Teoría de las redes neuronales....22

2.3.3 Aprendizaje automático y profundo....23

2.4 La termografía en los edificios....25

3 Desarrollo del TFG....30

3.1 Contexto del caso de estudio....30

3.2 Zonas estudiadas....34

3.3 Metodología de adquisición de imágenes térmicas....36

3.4 Etiquetado de las imágenes térmicas....39

3.5 Modelo de *Deep Learning* utilizado....41

3.6 Preparación del aprendizaje del modelo de *Deep Learning*....43

3.7 Descripción del código para ejecutar el modelo de *Deep Learning*....46

4 Resultados y discusión....49

4.1 Resultado del aprendizaje....49

4.1.1 Resultado del aprendizaje en el Escenario 1....49

4.1.2 Resultado del aprendizaje en el Escenario 2....51

4.2 Prestación del modelo aprendido aplicado a imágenes de cámaras térmicas low cost....52

5 Conclusiones y líneas futuras 63
5.1 Cumplimiento de los objetivos propuestos 63
5.2 Desafíos y líneas futuras de investigación 64
6 Bibliografía 65
Anexo I: Implicaciones Sociales, y/o Económicas, y/o Ambientales 69
ASPECTOS AMBIENTALES 69
ASPECTOS ECONÓMICOS 69
ASPECTOS INDUSTRIALES 70
ASPECTOS SOCIALES 70
Anexo II: Reflexiones Éticas y Sociales 71
REFLEXIONES ÉTICAS Y SOCIALES EN LA MEMORIA DEL TFG 71
REFLEXIÓN ÉTICA Y SOCIAL EN EL PLANO DEL TRABAJO DESARROLLADO 71

ÍNDICE DE FIGURAS

Figura 1-1 Imagen termográfica en el Laboratorio de Química del Centro Universitario de la Defensa sito en Marín, España. La leyenda de los valores de temperatura está ubicada en la paleta de colores en el margen derecho (Elaboración propia*)* 8

Figura 2-1 Patologías en los edificios: a) Humedad. b) Grieta (Elaboración propia) 12

Figura 2-2 Espectro electromagnético (Extraído de [7]) 13

Figura 2-3 Ley de Planck (Extraído de [10]) 14

Figura 2-4 Ley de Stefan-Boltzmann (Extraído de [11]) 16

Figura 2-5 Captación cámara termográfica (Extraído de [12]) 17

Figura 2-6 Historia de la termografía infrarroja (Extraído de [14]) 17

Figura 2-7 La cámara termográfica (Extraído de [17]) 18

Figura 2-8 Cámara termográfica a) Principales partes y b) Funcionamiento (Extraído de [19]) 19

Figura 2-9 Foco halógeno utilizado en termografía activa (Extraído de [24]) 20

Figura 2-10 Automatización de procesos (Extraído de [26]) 21

Figura 2-11 Funcionamiento simplificado de una neurona (Extraído de [30]) 23

Figura 2-12 Vertientes del aprendizaje automatizado (Extraído de [35]) 24

Figura 2-13 Termografía aplicada a edificios (Extraído de [38]) 25

Figura 2-14 Detección de puentes térmicos en fachadas a) imagen original, b) imagen con los puentes térmicos localizados (extraído de [41]) 26

Figura 2-15 Imagen térmica de infiltraciones de aire en el techo (extraído de [45]) 26

Figura 2-16 Uno de los resultados obtenidos con uno de los modelos DL, a) en los datos de entrada usados en el aprendizaje, b) en datos no empleados para el aprendizaje del modelo (extraído de [47]) 27

Figura 2-17 a) Predicciones obtenidas tras el aprendizaje del modelo ("W" significa humedad, "T" significa puente térmico). b) Referencia de las áreas reales de cada defecto en las imágenes térmicas de testeo, es decir, no usadas en el aprendizaje del modelo (extraído de [48]) 28

Figura 2-18 Uno de los (c) resultados con mayor precisión (84,3 %) obtenido. a) es la imagen térmica de entrada y b) la referencia del defecto (extraído de [46]) 29

Figura 3-1 Edificio de investigación CUD-ENM. a) Vista general. b) Plano primera planta (Extraído de [50]) 31

Figura 3-2 Situación geográfica del edificio de investigación en: a) Ría de Pontevedra (círculo amarillo), y en b) Escuela Naval Militar (rectángulo amarillo) (Elaboración propia usando Google Maps) 32

Figura 3-3 Cámara FLIR E85 (Extraído de [53]) 33

Figura 3-4 Cámara FLIR ONE EDGE (Extraído de [55]) 33

Figura 3-5 Numeración de las zonas con patologías estudiadas: a) en la primera planta, b) en la segunda planta (Elaboración propia) 35

Figura 3-6 Comparativa imagen térmica pasiva y activa: a) FLIR E85, b) FLIR ONE EDGE. Los recuadros insertados indican la localización de los defectos (a) grieta, b) humedad) (Elaboración propia) 37

Figura 3-7 Humedad en el laboratorio de química no identificable a vista humana en cámara digital (a)), pero sí en la cámara térmica (región azul) (b)) (Elaboración propia) 37

Figura 3-8 Grieta en el techo del pasillo principal del laboratorio (Elaboración propia) 39

Figura 3-9 Ejemplo de nomenclatura de las imágenes térmicas (Elaboración propia) 39

Figura 3-10 Página principal al abrir el software VGG Image Annotator, indicando opción carga de imágenes (Elaboración propia) 40

Figura 3-11 Identificación de una patología mediante la creación de un polígono y asignación de su tipología (Elaboración propia) 41

Figura 3-12 Código resultante JSON tras la identificación de los defectos (Elaboración propia)...41

Figura 3-13 Comparación Faster R-CNN (a)) y Mask R-CNN (b)) mediante ejemplos de resultados de dichos modelos (Extraídos de [58], [59]).....41

Figura 3-14 Esquema del funcionamiento de Mask R-CNN (Elaboración propia) 43

Figura 3-15 Modificaciones realizadas en la clase “CustomConfig” (Elaboración propia) 47

Figura 3-16 Modificaciones realizadas en la clase “CustomDataset”, a) definiendo los tipos de defectos, y b) el cross validation (Elaboración propia).....48

Figura 3-17 Modificaciones realizadas en la función “train” (Elaboración propia) 48

Figura 4-1 Gráfica del loss training del Escenario 1, marcando su línea de tendencia con puntos rojos (Elaboración propia) 49

Figura 4-2 Gráfica del loss validation del Escenario 1, marcando su línea de tendencia con puntos rojos (Elaboración propia) 50

Figura 4-3 Gráfica comparativa de entrenamiento y validación en el Escenario 1 (Elaboración propia) 50

Figura 4-4 Gráfica del loss training del Escenario 2, marcando su línea de tendencia con puntos rojos (Elaboración propia) 51

Figura 4-5 Gráfica del *loss validation* del Escenario 2, marcando su línea de tendencia con puntos rojos (Elaboración propia) 51

Figura 4-6 Gráfica comparativa de entrenamiento y validación en el Escenario 2 (Elaboración propia) 52

Figura 4-7 Diferencia entre precisión y exactitud (Extraído de [64]) 53

Figura 4-8 Resultados del Caso 1 (Zona 21) del Escenario 1 (Elaboración propia) 54

Figura 4-9 Resultados del Caso 2 (Zona 11) del Escenario 1 (Elaboración propia) 54

Figura 4-10 Resultados del Caso 3 (Zona 23) del Escenario 1 (Elaboración propia) 55

Figura 4-11 Resultados del Caso 4 (Zona 22) del Escenario 1 (Elaboración propia) 55

Figura 4-12 Resultados del Caso 5 (Zona 1) del Escenario 1 (activa) (Elaboración propia) 56

Figura 4-13 Resultados del Caso 5 (Zona 1) del Escenario 1 (pasiva) (Elaboración propia) 56

Figura 4-14 Resultados del Caso 6 (Zona 9) del Escenario 1 (activa) (Elaboración propia) 57

Figura 4-15 Resultados del Caso 6 (Zona 9) del Escenario 1 (pasiva) (Elaboración propia) 57

Figura 4-16 Resultados del Caso 7 (Zona 23) del Escenario 2 (Elaboración propia) 58
Figura 4-17 Resultados del Caso 8 (Zona 23) del Escenario 2 (Elaboración propia) 58
Figura 4-18 Resultados del Caso 9 del Escenario 2 (Elaboración propia) 59
Figura 4-19 Resultados del Caso 10 (Zona 21) del Escenario 2 (Elaboración propia) 59
Figura 4-20 Resultados del Caso 11 (Zona 17) del Escenario 2 (Elaboración propia) 60
Figura 4-21 Resultados del Caso 12 (Zona 9) del Escenario 2 (activa) (Elaboración propia) 60
Figura 4-22 Resultados del Caso 13 (Zona 4) del Escenario 2 (activa) (Elaboración propia) 60
Figura A1-1 Filtración de aire rompiendo el aislamiento térmico (Elaboración propia) 69

ÍNDICE DE TABLAS

Tabla 2-1 Subdivisión de la banda espectral infrarroja (Elaboración propia) 13
Tabla 3-1 Características cámara FLIR E85 y FLIR ONE EDGE (Elaboración propia) 34
Tabla 3-2 Comparativa de las patologías según tipo de imagen (Elaboración propia).....38
Tabla 3-3 Comparativa desde la imagen visible y térmica con la imagen que entra al modelo (Elaboración propia) 45
Tabla 4-1 Resultados diferenciando entre defecto y no defecto (Elaboración propia).....61
Tabla 4-2 Resultados diferenciando los diferentes tipos de defectos (Elaboración propia) 61

1 INTRODUCCIÓN Y OBJETIVOS

1.1 Contexto y motivación

Es fundamental, para mantener las condiciones óptimas de un edificio o cualquier otra construcción de interés, hacer un seguimiento constante, así como ser capaces de predecir cuál será su estado a lo largo del tiempo. En respuesta a esta creciente necesidad de prevenir y conservar estructuras ante posibles defectos y, a su vez, permitir la evaluación de la integridad estructural sin comprometer los materiales, toman importancia las Tecnologías No Destructivas (TND).

Las TND identifican tempranamente las imperfecciones en las edificaciones, tales como grietas y corrosiones, facilitando intervenciones preventivas antes de que estas se intensifiquen. Al no producirse intrusión con el objeto que se está sometiendo a estudio, se reducen los costes asociados a la reparación de elementos y se limita el periodo de inoperatividad de la edificación. Estas tecnologías mejoran la seguridad, prolongan la vida útil de las estructuras y contribuyen a la sostenibilidad.

La termografía infrarroja emerge como una TND líder, que es especialmente eficaz en la detección temprana de puentes térmicos, filtraciones de aire, humedades y grietas [1]. La razón de esto, es que es capaz de medir la temperatura de cualquier superficie mediante la traducción de los valores de radiación emitida por un cuerpo a valores de temperatura. Concretamente, la termografía infrarroja está basada en la radiación infrarroja, una radiación electromagnética ubicada en la banda espectral infrarroja, justo al lado de la banda espectral visible, con longitudes y frecuencias de onda más largas y más cortas, respectivamente, con respecto a dicha última banda. Según las Leyes de la Termodinámica, cualquier objeto que presente una temperatura por encima del cero absoluto emite una cierta radiación infrarroja, siendo así detectable por la termografía infrarroja. El ojo humano no puede ver este tipo de radiación, por lo que la medición de los datos se obtiene mediante el sensor térmico de una cámara de infrarrojos, también conocido como cámara térmica, a través de la cual se obtienen las diferentes imágenes que se someterán a estudio. Dichas imágenes son conocidas como imágenes térmicas o termográficas, en donde cada píxel representa un valor de temperatura determinado, valor el cuál será según la radiación infrarroja recibida en dicho píxel, siendo la conversión radiación a temperatura hecha internamente por la cámara térmica. Véase un ejemplo en la Figura 1-1.

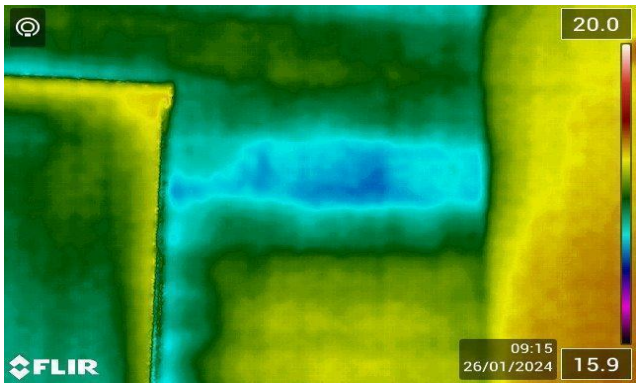


Figura 1-1 Imagen termográfica en el Laboratorio de Química del Centro Universitario de la Defensa sito en Marín, España. La leyenda de los valores de temperatura está ubicada en la paleta de colores en el margen derecho (Elaboración propia*)*

A través de estas imágenes térmicas, se pueden detectar y clasificar los diferentes defectos constructivos existentes en cualquier edificio/construcción debido a sus diferentes propiedades termofísicas frente al entorno sano de dicha infraestructura [2]. Al tener diferentes propiedades, el comportamiento térmico será diferente entre la región defectuosa con respecto a la región sana, siendo posible diferenciar las distintas huellas térmicas en las imágenes termográficas. En la Figura 1-1, por ejemplo, la región más azulada representa humedad en la pared.

El uso de imágenes térmicas es una buena estrategia a la hora de inspeccionar diferentes elementos constructivos sin la necesidad de contacto con la superficie sometida a estudio. La información recopilada se puede utilizar para la detección de problemas potenciales, programar intervenciones o establecer un mantenimiento preventivo para minimizar el riesgo de fallos. La automatización de la interpretación de estas imágenes se propone como solución para ayudar en la identificación de patologías existentes, acelerando el proceso de inspección [3].

La incorporación de redes neuronales como representantes destacados de la inteligencia artificial, ubicados dentro del grupo de aprendizaje profundo (*deep learning*), se presentan como una solución innovadora para potenciar la capacidad de análisis de datos termográficos de forma automatizada. Estas redes, tienen la capacidad de aprender patrones en las imágenes de entrada con el fin de poder realizar clasificaciones rápidas y precisas. Por lo tanto, una de las motivaciones principales de este Trabajo Fin de Grado (TFG) es la de aprovechar esta capacidad de procesamiento para lograr resultados de una manera automatizada en el estudio de los defectos existentes en la infraestructura objeto de estudio. Incluso, se va un paso más hacia adelante con este trabajo, inspeccionando hasta cuatro variedades diferentes de defectos, combinando banco de imágenes térmicas a partir de los dos modos de adquisición existentes en termografía infrarroja (pasiva y activa), y utilizando cámaras térmicas de bajo coste, *low cost*, siendo estos tres aspectos innovadores dentro del estado del arte.

La combinación de la termografía infrarroja y las redes neuronales abre un nuevo camino para la detección avanzada de defectos constructivos, contribuyendo al campo de la inspección no destructiva y proporcionando soluciones más rápidas, precisas y eficientes, garantizando la sostenibilidad y la seguridad de los edificios.

1.2 Objetivos

Los objetivos del presente Trabajo Fin de Grado se estructuran de la siguiente manera:

- Análisis de la importancia de la prevención y conservación en los edificios para poder cumplir con los objetivos de la Agenda 2030 en lo que respecta a la mitigación de posibles defectos constructivos, tales como puentes térmicos, filtraciones de aire, grietas y humedades.

- Exploración de la termografía infrarroja como tecnología clave en la prevención de defectos constructivos: Explorar las ventajas y limitaciones de dicha tecnología. Familiarizarse con esta técnica y dominar su uso.
- Implementación de técnicas de *deep learning* en la identificación automatizada de defectos constructivos: A través de todas las imágenes térmicas obtenidas de las cámaras termográficas utilizadas, aplicar y desarrollar técnicas de *deep learning* capaces de detectar las deficiencias de manera automatizada, tanto en indicar la existencia del defecto como en clasificarlo según su tipología.
- Comparar la eficacia de los modelos de *deep learning* utilizando imágenes termográficas adquiridas de manera pasiva y activa.
- Comparativa de cámaras termográficas, evaluando los resultados obtenidos con cámaras *low cost* y de alta gama. Se estudiará la diferencia de prestaciones de ambas cámaras, así como las limitaciones detectadas en aquellas de baja gama.

1.3 Metodología

La aproximación al problema se llevará a cabo seleccionando el Edificio de Investigación del Centro Universitario de la Defensa de Marín, ubicado en la Escuela Naval Militar (CUD-ENM), como objeto de estudio. La descripción de la metodología seguida, en secuencia cronológica, se cita a continuación:

- Obtención de imágenes térmicas en el edificio en cuestión mediante una cámara termográfica de alta gama y una *low cost*, buscando como zonas candidatas de estudio aquellas susceptibles de presentar más defectos/problemas. Las imágenes han sido adquiridas de manera activa (mediante la utilización de un foco lumínico halógeno como aporte de calor a la superficie bajo estudio) y pasiva, es decir, realizando capturas de imágenes de manera natural (sin aporte de calor por parte de otras fuentes, solamente de la luz solar). Las adquisiciones se hicieron tanto desde el interior como desde el exterior
- Procesamiento de las imágenes térmicas adquiridas para su posterior utilización/aprendizaje de la rede neuronal utilizada. Se etiqueta en cada imagen mediante el trazado del contorno de la huella térmica de cada defecto existente, para introducir en la red tanto las imágenes como los trazados correspondientes como datos de entrada del aprendizaje a ejecutar.
- Ejecución y análisis de los resultados obtenidos del aprendizaje de la red neuronal. Validación de la misma como sistema automatizado de detección de deficiencias en la edificación en imágenes térmicas nuevas que no fueron utilizadas para el aprendizaje.
- Extracción de conclusiones y líneas futuras de trabajo.

1.4 Estructura de la memoria

El presente proyecto se estructurará en 5 capítulos diferentes. El presente capítulo, de Introducción y objetivos, sirve como punto de partida para establecer el contexto, metas que se persiguen y cronología del trabajo.

Una vez establecido el marco inicial, el capítulo 2 corresponderá al Estado del Arte. Este servirá para comprender el panorama actual y las contribuciones más relevantes que han dado forma al campo de investigación de la termografía infrarroja relacionado al ámbito de este trabajo.

Con esta base, el siguiente capítulo se adentra en el Desarrollo del TFG. Es en este apartado 3, donde se detalla el procedimiento seguido en el trabajo, desde el material utilizado hasta su ejecución práctica (adquisición de imágenes, etiquetado de ellas, utilización de la red neuronal), explicando en detalle el método empleado para la consecución de los objetivos, proporcionando así al lector una visión clara del trabajo realizado.

Obtenidos los resultados, el capítulo cuarto se centrará en el análisis de estos, Resultados y discusión. Se examinarán con detenimiento los hallazgos obtenidos (resultado del aprendizaje de la red neuronal,

y prestación de la red en imágenes térmicas no utilizadas en el aprendizaje) a través de la identificación de los patrones y se extraen conclusiones significativas.

Finalmente, el último y quinto capítulo presentará las conclusiones del Trabajo Fin de Grado, donde se destacarán las contribuciones realizadas y se señalarán las posibles direcciones futuras para la investigación.

2 ESTADO DEL ARTE

2.1 Patologías en edificios

Los edificios, en general, están expuestos a la acción de distintos fenómenos meteorológicos que, a lo largo del tiempo, se pueden convertir en agentes "degradantes", como la lluvia, las variaciones bruscas de temperatura, la humedad, el salitre, viento, etc. Además, también pueden deber su deterioro a la acción humana que se ha llevado a cabo en ellos, como por ejemplo la sobrecarga de peso o el mal uso de las instalaciones. Debido a todo esto, se vuelve una tarea conveniente la evaluación de sus materiales constructivos, en un primer lugar, para prevenir la aparición de patologías y, en segundo lugar, para poder llevar a cabo la reforma o rehabilitación de esas infraestructuras en caso de que comenzase el deterioro de estas [4]. A continuación, se presenta un resumen de las patologías más frecuentes en edificios, mostrándose en la Figura 2-1 dos ejemplos de las citadas patologías:

- **Fisuras y grietas:** Se tratan de pequeñas aberturas que se forman en la estructura de un edificio generalmente debidas a tensiones, movimientos o deformaciones. Hace peligrar la estabilidad del edificio.
- **Humedades y filtraciones de agua:** Presencia no deseada de agua que penetra en un edificio, provocando manchas, moho y deterioro de materiales, peligrando la estabilidad de la estructura, además de perjudicar a la salud respiratoria de los usuarios.
- **Corrosión y deterioro de materiales:** La exposición de los edificios a diferentes agentes atmosféricos puede provocar que estos se desgasten, afectando a su resistencia y estabilidad.
- **Puentes térmicos:** Los puentes térmicos son áreas en la estructura de un edificio donde se produce una interrupción en el aislamiento térmico, lo que provoca pérdidas de calor o frío desde el interior según se esté en invierno o en verano, respectivamente. Estos puntos débiles pueden resultar en un aumento del consumo de energía y en problemas de confort térmico en el interior de dichos edificios.
- **Filtración de aire:** Las filtraciones de aire en los edificios son fugas no deseadas de aire que pueden ocurrir a través de grietas, juntas o aberturas en la envolvente del edificio. Estos puntos débiles, al igual que los puentes térmicos, pueden resultar en un aumento del consumo de energía y en problemas de confort térmico en el interior de dichos edificios.

La identificación temprana y la correcta gestión de estas patologías son esenciales para garantizar la longevidad, seguridad y funcionalidad de los edificios a lo largo del tiempo. En este contexto, la aplicación de la termografía infrarroja surge como una herramienta valiosa para la detección y evaluación de estos defectos constructivos.



a) **b)**

Figura 2-1 Patologías en los edificios: a) Humedad. b) Grieta (Elaboración propia)

2.2 La termografía infrarroja

La temperatura se trata de una variable física fundamental, cuyo conocimiento y control otorga una gran cantidad de ventajas. Esta variable es de gran importancia para la termografía infrarroja. La termografía infrarroja es una tecnología no destructiva que mide la radiación emitida de cuerpos en la banda infrarroja del espectro electromagnético. Gracias a los sensores de las cámaras térmicas, se puede captar la radiación infrarroja emitida por un objeto, y gracias a sus circuitos internos, transformarla en valores de temperatura, para poder estudiar así el comportamiento térmico de los objetos sometidos a estudio. Existe una gran lista de motivos por los que la termografía infrarroja puede resultar útil, entre los cuales cabe destacar los siguientes [5]:

- **Medida instantánea:** Gracias a las cámaras termográficas, se puede observar en tiempo real la situación térmica del objeto o el entorno sobre el cual se está realizando una inspección o estudio, lo que permite no solo el escaneo con alta velocidad de objetos estacionarios, sino también la adquisición de objetos en movimiento rápido y de patrones térmicos que cambian rápidamente.
- **No contacto y no es invasiva:** Los dispositivos utilizados no están en contacto con la fuente de calor, es decir, son termómetros sin contacto. De esta manera, se puede medir la temperatura de objetos peligrosos por sus condiciones térmicas o delicados de manera segura, manteniendo al usuario a una distancia del objeto sometido a estudio. Esta característica se trata de una de las mayores ventajas del uso de la termografía infrarroja, ya que permite realizar una evaluación de un edificio sin tener que paralizar la actividad que en él se esté desarrollando y además no produce daños a los objetos a analizar.
- **Es bidimensional:** Presenta la gran ventaja de poder medir la temperatura en uno o más objetos simultáneamente, permitiendo una comparación entre áreas del objetivo.
- **Multidisciplinar:** Además de la temperatura, la termografía infrarroja permite el estudio de otros factores como anomalías, patrones térmicos, etc.

Cualquier objeto emite radiación electromagnética según las Leyes de la Termodinámica, ya que no existe el 0 K absoluto y por tanto ninguna estructura atómica totalmente inmóvil, y dicha radiación es característica de ese objeto, es decir, al movimiento y vibración que tenga sus átomos, permitiendo así identificarlo y clasificarlo, como si de una huella digital se tratara. La distribución energética de cualquiera radiación electromagnética se ubica dentro el espectro electromagnético. Dentro de este espectro se encuentran la banda espectral de la luz visible, que es la única que el ser humano puede

percibir con el sentido de la vista, y la banda espectral infrarroja, relacionada directamente con la termografía infrarrojo [6].

En la Figura 2-2 se muestra el espectro electromagnético, donde se puede observar la zona ocupada por el espectro visible e infrarrojo, y a continuación, en la Tabla 2-1 una subdivisión de las capas que conforman el infrarrojo.

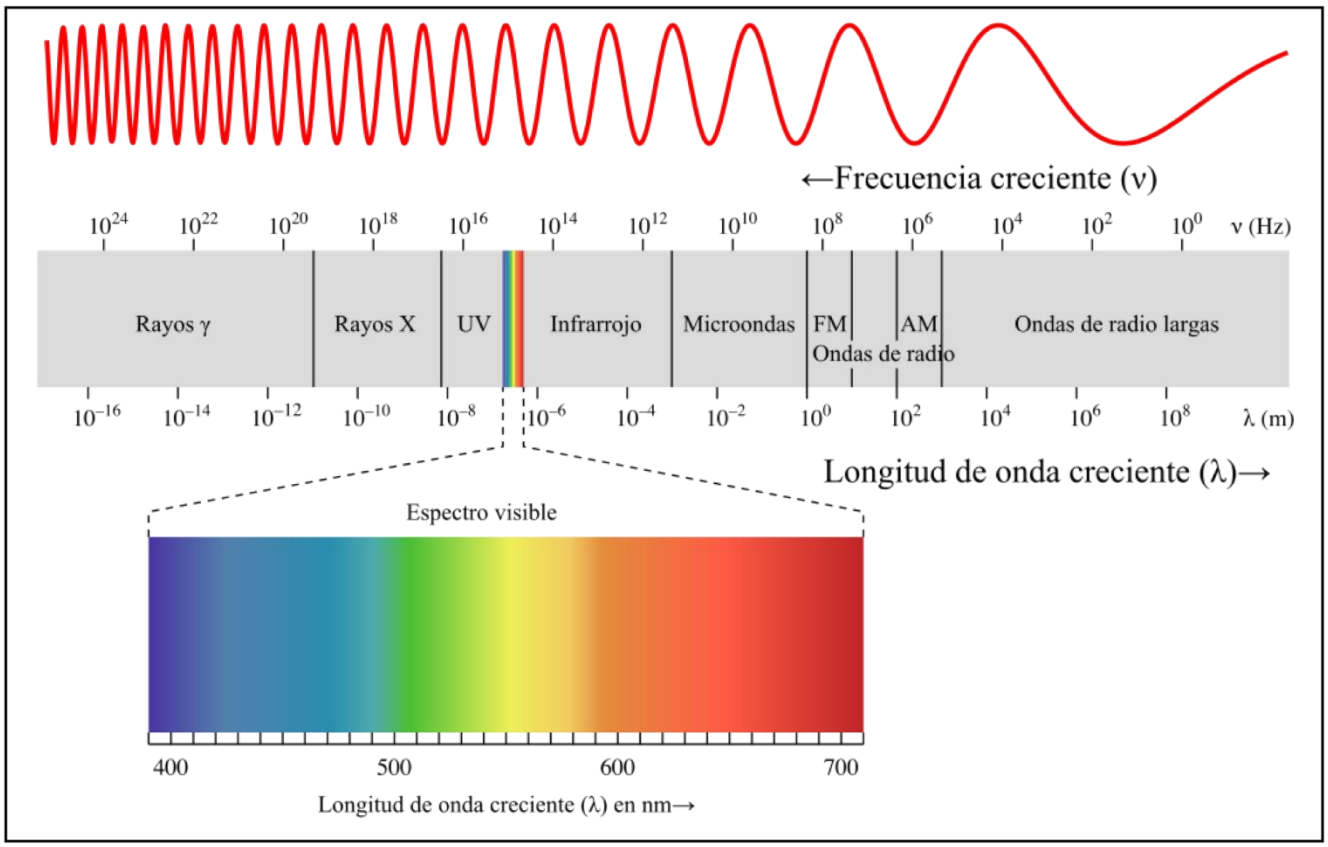


Figura 2-2 Espectro electromagnético (Extraído de [7])

Nombre división	Abreviatura	Horquilla longitud de onda (µm)
Near-infrared	NIR	0,7-1,4
Short-wavelength infrared	SWIR	1,4-3
Mid-wavelength infrared	MWIR	3-5
Long-wavelength infrared	LWIR	8-15
Far-infrared	FIR	15-1000

Tabla 2-1 Subdivisión de la banda espectral infrarroja (Elaboración propia)

Se destaca que la radiación de interés dentro de la termografía infrarroja es solamente la comprendida dentro de la banda infrarroja, ya que la correlación entre la radiación emitida y la temperatura correspondiente de un cuerpo alcanza el máximo en esa banda, de ahí que las cámaras térmicas sean sensibles solamente en esa franja espectral ya que es más fácil la medición. Incluso, en condiciones ambientales, las cámaras solamente son sensibles a la sub-banda infrarroja térmica (*long-wavelength infrared*, ver Tabla 2-1). De ahí el nombre de dicha tecnología, termografía infrarroja [2].

Por otra parte, las patologías existentes en los cuerpos, objetos, infraestructuras, etc. tienen un comportamiento térmico diferente entre ellas debido a sus distintas propiedades termofísicas, y también frente a las regiones sanas. Es por ello por lo que entra en juego la termografía infrarroja que, gracias a ese comportamiento diferencial, puede detectar los puntos donde se encuentran presentes esas deficiencias, e incluso diferenciarlas entre ellas. Además, la tecnología infrarroja también permite caracterizar térmicamente las propiedades de los materiales que componen una estructura, pudiendo así conocer la demanda energética de los edificios [7].

2.2.1 Marco teórico de la termografía infrarroja

La radiación infrarroja es la energía que se emite desde la superficie de un objeto según el movimiento entre sus átomos y sus vibraciones. La temperatura está directamente relacionada a la emisión del material: a medida que la intensidad de la energía infrarroja emitida aumenta, también aumenta la temperatura.

Los factores que hay que tener en cuenta en la conversión de radiación infrarroja a temperatura, son [8]:

- **La emisividad:** Se refiere a la eficiencia con la que un cuerpo emite radiación.
- **La reflectividad:** Todas las reflexiones recibidas por parte del entorno deben de ser tenidas en cuenta a la hora de adquirir la información térmica de un objeto. Es la diferencia para que llegase la emisividad a la eficiencia óptima.
- **Temperatura del entorno:** Un sensor térmico no sólo tiene en cuenta la radiación emitida por el cuerpo sometido a estudio, sino también del resto de cuerpos a temperatura ambiente presentes. Está vinculada a la reflectividad.
- **Temperatura y humedad relativa de la atmósfera, y distancia entre objeto y cámara térmica:** Altera el resultado de la señal electromagnética recibida por la cámara debido a la temperatura y humedad relativa ambiental, y distancia entre objeto y cámara, ya que la capa atmosférica absorbe en parte la radiación emitida por el objeto.

Existen tres formas en que la energía radiante que golpea un objeto puede disiparse: absorción, transmisión y reflexión. Las fracciones de la energía radiante total que están asociadas con cada uno de estos modos de disipación se denominan absortividad (α), transmisividad (τ) y reflectividad (ρ) del cuerpo, respectivamente [9]. Estos parámetros son dependientes de la longitud de onda y su suma debe de ser uno en cualquier longitud de onda, resultando la Ecuación (1):

$$\alpha + \tau + \rho = 1 \qquad \text{(Ecuación 1)}$$

La ley de radiación de Planck describe la distribución espectral de la radiación emitida por un cuerpo negro en función de la longitud de onda y la temperatura, como se muestra en la Figura 2-3.

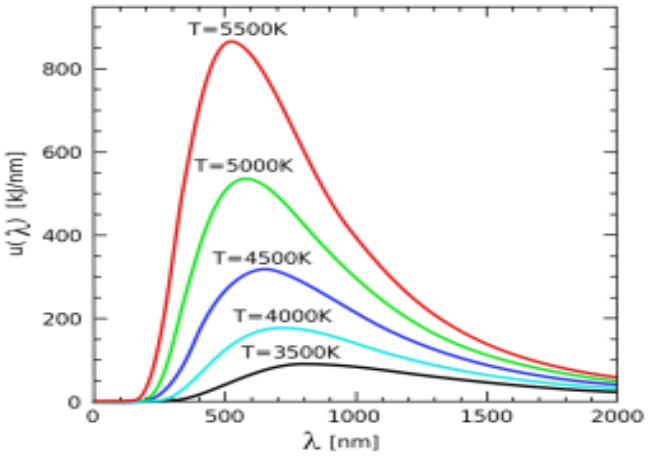


Figura 2-3 Ley de Planck (Extraído de [10])

La energía radiante se emite y se absorbe en forma de paquetes discretos llamados cuantos, o fotones, y la cantidad de radiación emitida por unidad de longitud de onda (γ) y por unidad de área es proporcional a la frecuencia de la radiación y a la temperatura absoluta elevada a menos uno. Así, la radiación electromagnética emitida por un cuerpo negro (Wb) se puede calcular utilizando la Ecuación (2), donde C1 y C2 son constantes, γ es la longitud de onda y T es la temperatura:

$$Wb = \frac{C1}{\gamma^5} \cdot \frac{1}{e^{\frac{C2}{\gamma T}} - 1} \qquad \text{(Ecuación 2)}$$

La longitud de onda a la cual se emite la máxima radiación electromagnética depende de la temperatura del objeto; cuanto mayor sea su temperatura, menor será su longitud de onda, es decir, a temperaturas más altas, la radiación emitida se vuelve más energética y cambia hacia el rango de la luz visible y ultravioleta.

El pico de longitud de onda para un valor de temperatura específico se puede calcular utilizando la Ley de Wien, como se muestra en la Ecuación (3). Esta ley, establece que la longitud de onda en la cual un cuerpo negro emite la mayor cantidad de radiación está inversamente relacionada con su temperatura absoluta (T). De ahí que, en condiciones ambientes, la longitud de onda se abarca dentro de la banda espectral infrarroja, concretamente en la sub-banda infrarroja térmica (*long-wavelength infrared*, ver Tabla 2-1), y por tanto las cámaras térmicas muchas de ellas sensibles a esa sub-banda.

$$\gamma_{pico} = \frac{0{,}0029}{T} \qquad \text{(Ecuación 3)}$$

Integrando la Ecuación (2) a través de la banda espectral infrarroja, se obtiene la Ecuación (4), donde σ es una constante, llegando así a la fórmula de Stefan-Boltzmann, en donde se describe cómo la energía radiante emitida por un cuerpo negro está relacionada con su temperatura:

$$Wb = \sigma \cdot T^4 \qquad \text{(Ecuación 4)}$$

En cuanto a la emisividad de un cuerpo, se define formalmente para una longitud de onda mediante la Ecuación (5), como la relación entre la energía radiante emitida por el cuerpo y la radiación que sería emitida por un cuerpo negro a la misma temperatura. El valor de la emisividad abarca un rango entre 0,1-0,99, indicando así que un cuerpo real, conocido también como cuerpo gris, emite siempre menor radiación con respecto a un cuerpo negro en la misma longitud de onda. Como cuerpo negro solamente existe en la naturaleza el propio Sol, siendo en la práctica solamente posible mediante la construcción de cuerpos artificiales.

$$\varepsilon_\gamma = \frac{W_\gamma}{W_{\gamma b}} \qquad \text{(Ecuación 5)}$$

En otras palabras, un cuerpo real emite solo una fracción de la energía emitida por un cuerpo negro a la misma temperatura. Por lo tanto, la Ecuación (5) se puede expresar como la Ecuación (6):

$$\varepsilon_\gamma = \frac{W_\gamma}{W_{\gamma b}} = \frac{W}{W_b} = \varepsilon \qquad \text{(Ecuación 6)}$$

Un cuerpo negro se define como un cuerpo ideal que emite toda la radiación recibida de acuerdo con su estado térmico. Sin embargo, los cuerpos ideales no existen y, como resultado, para el propósito de analizar la respuesta ideal de un objeto frente a cierta radiación, se fabrican "simuladores de cuerpo negro". Con esto, se deduce que los cuerpos reales nunca podrán emitir toda la radiación recibida en relación con sus temperaturas [9]. Por lo tanto, en termografía infrarroja, la emisividad (ε) se define

como un parámetro que indica la relación entre la radiación infrarroja emitida por un cuerpo real ("cuerpo gris") y la de un cuerpo negro a la misma temperatura. Como consecuencia, la adaptación de la ley de Stefan-Boltzmann, Ecuación (4), a cuerpos reales implica la introducción del parámetro de emisividad como se aprecia en la Ecuación (7). A continuación, además de la Ecuación (7), también se puede observar una gráfica en la Figura 2-4 de la citada Ley, donde se puede contemplar que la radiación aumenta exponencialmente con la temperatura del objeto, siguiendo una curva parabólica:

$$W = \sigma \cdot T^4 \cdot \mathcal{E}$$

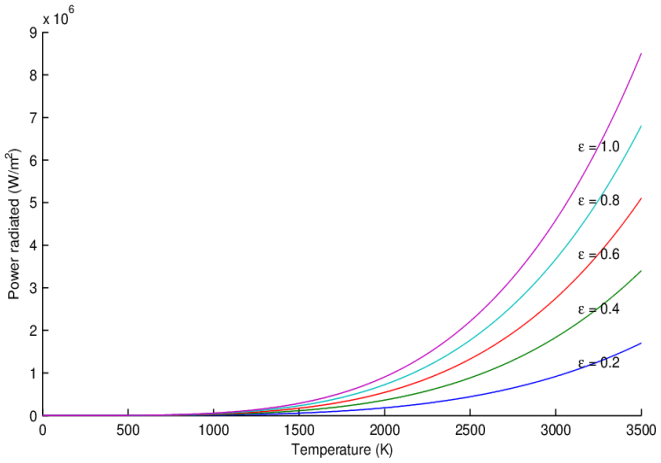


Figura 2-4 Ley de Stefan-Boltzmann (Extraído de [11])

Las medidas finales de un sistema de captación están condicionadas por diferentes agentes. En el caso de las cámaras termográficas, la medida final puede dividirse en 3 partes. La primera de ellas es la radiación debida a la emisión del objeto (Wobj) (Ecuación 7), la segunda la radiación reflejada en el objeto debido a la temperatura de los objetos del entorno (Wref), que viene siendo la Ecuación (7) pero a la emisividad restándole una unidad en términos absolutos y la temperatura del objeto sustituyendo por la temperatura media de los objetos del entorno. Por último, la radiación debida a la atmósfera circundante (Watm), que viene siendo la Ecuación (7) pero sustituyendo la temperatura del objeto a la temperatura de la atmósfera en el momento de la medición.

En la Figura 2-5 se puede apreciar el proceso anteriormente comentado y finalmente, con la suma de todas ellas se obtiene la Ecuación (8), destacando que se tiene en cuenta el factor de la transmitancia atmosférica (T), en tanto por uno, para cuantificar cuánto de Watm capta realmente la cámara térmica en detrimento de Wobj y Wref, obteniendo T a partir de la medición de la temperatura y humedad relativa atmosférica, y distancia entre objeto y cámara. De ahí lo comentado de los factores citados al inicio del apartado, para tener valores de temperatura precisos, en caso contrario se denominarían temperaturas aparentes. Por lo general, esos factores se obtienen a pie de campo y se introducen en la configuración de la cámara térmica, y ella internamente aplica la Ecuación (8) para la conversión de la radiación a temperatura del objeto.

$$Wtot = T \cdot Wobj + T \cdot Wref + (1 - T) \cdot Watm \qquad \text{(Ecuación 8)}$$

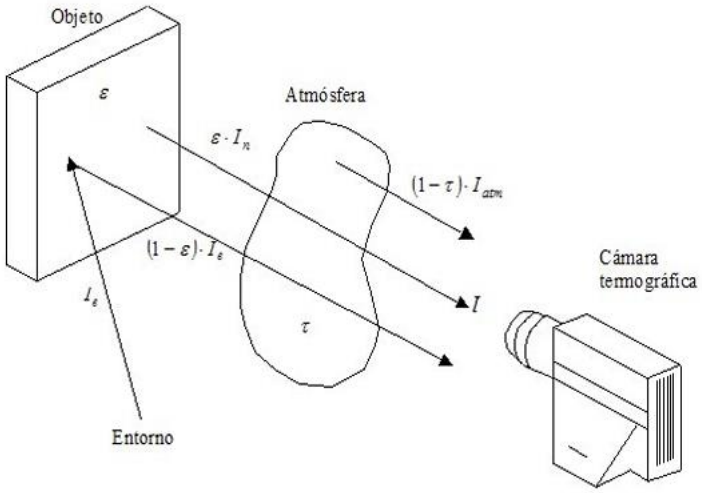


Figura 2-5 Captación cámara termográfica (Extraído de [12])

Si toda la radiación incidente es absorbida por un objeto (sin transmisión ni reflexión), su absortividad es igual a uno. A temperatura constante, toda la energía absorbida debe ser reemitida, lo que implicaría que la emisividad de dicho cuerpo sería de uno. Por lo tanto, según la ley de Kirchhoff, un cuerpo que emite cierta cantidad de radiación infrarroja también absorberá esa misma cantidad de radiación a una temperatura dada, lo que indica que la capacidad de un objeto para emitir radiación infrarroja es proporcional a su capacidad para absorberla, lo que se expresa en la Ecuación (9):

$$\varepsilon_\gamma = \alpha_\gamma \qquad \text{(Ecuación 9)}$$

2.2.2 Contexto histórico de la termografía infrarroja

La termografía infrarroja ha experimentado una gran evolución a lo largo del tiempo, desempeñando un papel crucial en diversos campos de la investigación. Desde su descubrimiento, pasando por los hitos más relevantes hasta el día de hoy, se puede estudiar su trayectoria histórica.

El espectro infrarrojo fue descubierto por Herschel en el año 1800. Se trató de un descubrimiento accidental, ya que este sólo buscaba un material para reducir el brillo del sol en los telescopios, pero le llamó la atención la diferencia de calor que dejaban pasar unos y otros filtros, véase la Figura 2-6. Este fenómeno le resultó interesante y comenzó a interesarse, llegando a encontrar el punto donde el efecto calorífico fuese máximo, que lo denominó “espectro termométrico” [13].

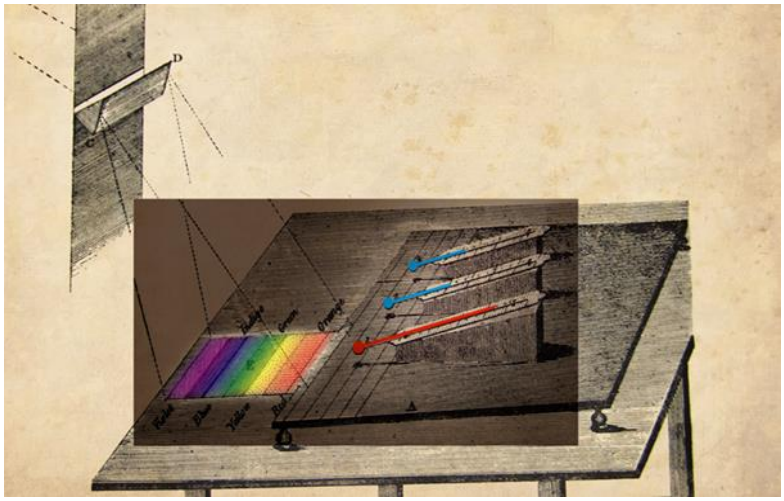


Figura 2-6 Historia de la termografía infrarroja (Extraído de [14])

La evolución de la termografía infrarrojaº fue lenta, ocurriendo algún descubrimiento durante el siglo XIX, pero no fue hasta las dos primeras décadas del siglo XX cuando se descubrieron los "infrarrojos". En las décadas siguientes, se realizaron avances en la fabricación de detectores infrarrojos utilizando materiales como selenio y telurio, sentando las bases para el desarrollo de dispositivos sensibles a la radiación infrarroja.

Como suele ser habitual, la guerra ha propiciado grandes avances tecnológicos, llevando la termografía infrarroja a aplicaciones militares cruciales. Fue durante la Primera Guerra Mundial cuando se crearon sistemas realmente modernos para la detección de objetos a grandes distancias. Entre la Primera y la Segunda Guerra Mundial se elaboraron dos de los detectores infrarrojos más importantes: el conversor de imágenes y el detector de fotones.

Tras la guerra, desde principios de la década de 1950, toda la información de la termografía infrarroja estuvo a disposición de los científicos, dando lugar al desarrollo de cámaras termográficas más compactas y accesibles. Con el paso de los años, se lograron notables mejoras en la resolución y sensibilidad de las cámaras termográficas, otorgando a estas una mayor precisión en la detección y análisis [15].

Ya fue en las últimas décadas cuando la termografía infrarroja ha experimentado avances con tecnologías más avanzadas, hasta llegar a los tiempos actuales, donde esta tecnología es crucial en campos como la investigación científica, la industria, la medicina o la seguridad [5].

2.2.3 La cámara termográfica

Las cámaras térmicas son dispositivos pasivos que capturan la radiación infrarroja emitida por cualquiera objeto. Inicialmente fueron diseñadas para uso militar en vigilancia y visión nocturna. Con el paso de los años, su precio ha disminuido, ampliando así su campo de aplicaciones. La incorporación de estos sensores en sistemas de visión soluciona los problemas de iluminación encontrados en cámaras estándar, es decir, cámaras convencionales/visibles, en escala de grises y RGB (*Red-Green-Blue*) [16].

Estas cámaras térmicas han emergido como herramientas claves en diversas disciplinas, ofreciendo la capacidad de visualizar y analizar patrones de radiación infrarroja de forma eficiente. Este tipo de cámara genera una señal respecto a la energía recibida que dependerá de la temperatura del cuerpo o superficie observados, aplicando la Ecuación (8) y proporcionando una imagen con una escala de colores que depende de la temperatura a la que se encuentre el objeto de estudio, tal y como se puede observar en la Figura 2-7.

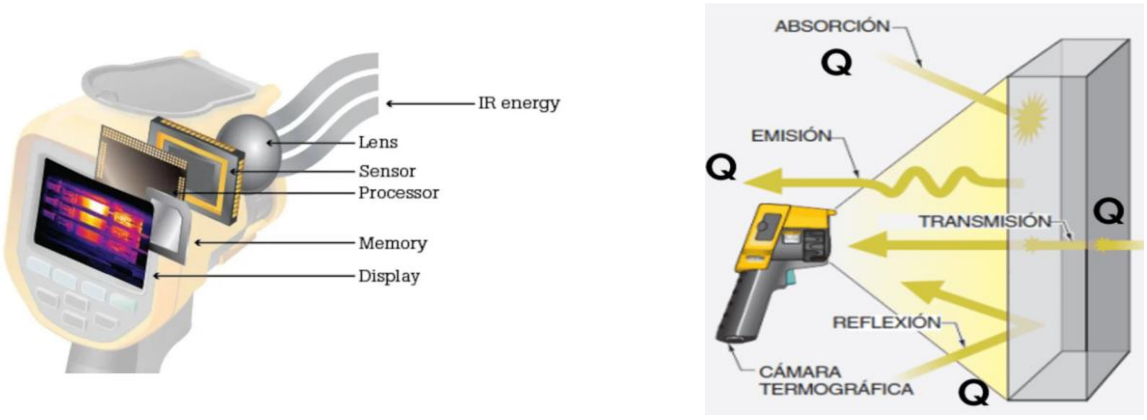


Figura 2-7 La cámara termográfica (Extraído de [17])

Los detectores utilizados en estas cámaras son habitualmente de dos tipos: detectores de fotones o detectores térmicos. Los primeros trabajan en la banda de longitud de onda media (*Mid-wavelength infrared*, ver Tabla 2-1), donde el contraste térmico es alto, lo que la hace especialmente sensible a los pequeños cambios de temperatura. Mientras tanto, los detectores térmicos trabajan en una banda de longitud de onda larga (*Long-wavelength infrared*, ver Tabla 2-1) y pueden funcionar con detectores ferroeléctricos y microbolómetros, y son los más utilizados por su alta precisión y mayor resolución espacial, sobre todo si se trabaja en condiciones ambientales [18].

La cámara termográfica está principalmente compuesta por una lente óptica, un sensor térmico, un procesador y una memoria, como se puede observar en la Figura 2-8 a). A continuación, en los siguientes párrafos, se describe su funcionamiento acompañado por la Figura 2-8 b).

Primero, la lente permite enfocar la radiación infrarroja proveniente del objeto hacia el sensor y este, que se trata del componente clave que detecta la radiación infrarroja emitida por los objetos, convierte la energía infrarroja en una señal eléctrica. Posteriormente, el procesador convierte esta señal en una imagen térmica visible en la pantalla ejecutando en el procesador la Ecuación (8), donde los diferentes tonos de color representan las diferentes temperaturas del cuerpo sometido a estudio.



a) **b)**

Figura 2-8 Cámara termográfica a) Principales partes y b) Funcionamiento (Extraído de [19])

Por último, tras capturar las imágenes, estas se almacenan en la memoria de la cámara, las cuales pueden ser visualizadas en un ordenador mediante el uso de la aplicación correspondiente [20].

La cámara térmica ofrece una serie de patrones térmicos, que se pueden manejar al gusto del usuario dependiendo de la respuesta que se espera obtener. Hay que tener en cuenta que se deben de ajustar de manera correcta estos patrones, ya que, de no hacerlo, los resultados obtenidos serían inexactos y equívocos.

2.2.4 Modos de trabajo de la termografía infrarroja

Se puede hablar de termografía infrarroja desde dos enfoques diferentes con respecto a su modo de adquisición: pasivo y activo. En la pasiva, se mide la radiación proveniente del objeto sin ninguna estimulación térmica artificial externa, utilizando esta información para medir la temperatura natural del objeto, y por tanto su comportamiento termofísico real. Esto se debe a que la medición se realiza en condiciones ambientales, es decir, el objeto no se ve excitado térmicamente por una fuente artificial. Por otro lado, en la activa, la muestra se somete a una estimulación térmica artificial externa, sin centrarse en el comportamiento termo físico real del objeto, sino más bien en los posibles defectos de su composición interna, dado que la transmitancia térmica aplicada por la luz solar no es lo suficientemente intensa para poder visualizar huellas térmicas de defectos internos en la superficie de dicho objeto.

La pasiva suele ser utilizada en aplicaciones de control de calidad y monitoreo de procesos, ya que la temperatura juega un papel crucial en cualquier proceso industrial. Por lo tanto, la medición y la monitorización de la temperatura durante y después del proceso industrial son fundamentales para lograr resultados óptimos, como por ejemplo la laminación de acero. No obstante, el cálculo de la temperatura a partir de imágenes térmicas no se basa únicamente en la radiación medida, también depende de la calibración interna de la cámara, así como de la emisividad del objeto que irradia energía. Por lo tanto, se requiere una configuración de calibración para obtener mediciones precisas [21].

Por su parte, la activa se utiliza principalmente en aplicaciones de pruebas no destructivas, donde se aplica un estímulo externo a la muestra para inducir contrastes térmicos relevantes entre regiones de interés. Se aplica a la inspección de materiales para la detección de defectos subsuperficiales y también para detectar áreas de la muestra con diferentes propiedades debajo de la superficie. Algunas anomalías subsuperficiales son muy sutiles por lo que los niveles de señal asociados con ellas pueden perderse en el ruido de los datos termográficos. En estos casos, se pueden utilizar diferentes métodos de post-procesamiento para mejorar el contenido de relación señal-ruido (*Signal to Noise Ratio*, SNR) de los datos termográficos [22].

Las técnicas ópticas, utilizadas en la termografía infrarroja activa, más populares son las lámparas de destello, que emiten pulsos de energía y lámparas halógenas, como la que se presenta en la Figura 2-9, tanto para calentamiento continuo como modulado [23]. Ambas tecnologías pueden utilizarse para estimular áreas grandes o pequeñas cambiando el número de lámparas, analizando no solo la fase de enfriamiento, sino también la fase de calentamiento, y proporcionando una alta tasa de repetibilidad.

Con respecto a cómo analizar las imágenes térmicas adquiridas, se tiene también dos enfoques diferentes: cualitativo y cuantitativo. El análisis cualitativo es aquel en el que el objetivo sea medir la distribución de temperatura de un objeto mediante la obtención de los valores relativos de cada uno de los píxeles de la imagen térmica correspondiente. Este propósito se lleva a cabo en casos en los que se desea detectar la existencia de patologías térmicas, o diferenciar objetos entre sí, siendo suficiente trabajar con temperaturas aparentes. Por otro lado, si el objetivo del estudio es obtener valores de temperatura precisos, se llevará a cabo un análisis cuantitativo. Para ello, será necesario obtener los parámetros comentados en el apartado 2.2.1, destacando que, en cualitativo, se dejaría en valores estándar para cada parámetro sin tener en cuenta la escena real, desvirtuando así lo mínimo posible las temperaturas aparentes. El análisis cuantitativo se lleva a cabo en casos en los que sea necesario clasificar las posibles patologías en el objeto a investigar según su severidad, así como calcular las propiedades termo físicas de las anomalías detectadas o del objeto en sí.



Figura 2-9 Foco halógeno utilizado en termografía activa (Extraído de [24])

2.3 Automatización de los resultados termográficos

La constante innovación tecnológica y la existencia de las cámaras termográficas, que poseen sensores modernos y de alto pixelaje, han permitido digitalizar con mayor fiabilidad las diferentes imágenes termográficas y dando lugar a una nueva línea de investigación denominada Visión Artificial. Esta, está enfocada a generar algoritmos para mejorar la calidad de las imágenes, segmentar las características de interés y reconocer patrones para la solución de problemas, seguridad o automatización de resultados, entre otros [25]. El procesamiento de imágenes térmicas ha evolucionado con el desarrollo de algoritmos avanzados que permiten una evaluación más rápida y automatizada. Gracias a algoritmos de aprendizaje, que se entrenan a partir de un conjunto de datos proporcionado por el usuario, se puede, de un modo automatizado, identificar patrones térmicos anómalos, facilitando la detección de defectos constructivos y deterioros de los edificios. En la Figura 2-10 se puede observar el ciclo de la automatización de procesos.

Además, dentro de los algoritmos de aprendizaje, la integración de la Inteligencia Artificial (IA) ha llevado a la creación de sistemas automatizados más sofisticados. Redes neuronales y otras arquitecturas de aprendizaje pueden ser utilizadas para realizar el análisis automático de las imágenes obtenidas por las cámaras termográficas.

A continuación, se presentan algunas de las características diferenciales que se obtienen gracias a la automatización de resultados:

- **Extracción de características:** Facilita la identificación de patrones térmicos, contornos y características específicas para tareas particulares.
- **Detección y clasificación:** Se han desarrollado modelos de *deep learning* capaces de clasificar objetos y detectar condiciones específicas en imágenes térmicas.
- **Análisis temporal:** Este enfoque es crucial en aplicaciones donde la evolución temporal de las condiciones térmicas desempeña un papel fundamental, como estimar la profundidad de cada defecto interno existente en un objeto.
- **Aprendizaje no supervisado:** No es necesario hacer un trabajo manual previo, el propio programa es capaz de hacerlo por su cu**enta.**
- **Despliegue en tiempo real:** Gracias a esto, es posible obtener los resultados pocos minutos después de obtener la imagen térmica.

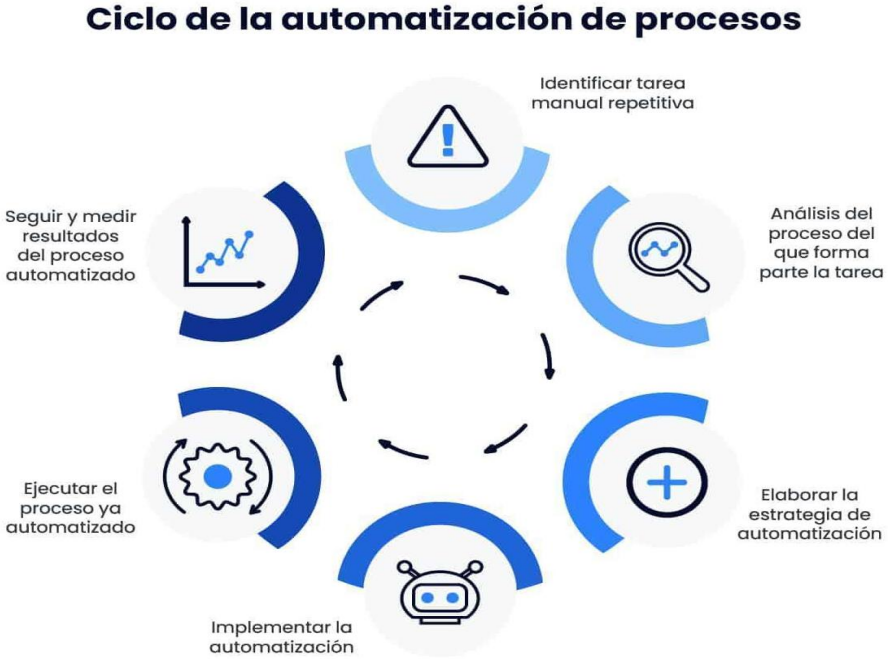


Figura 2-10 Automatización de procesos (Extraído de [26])

2.3.1 Inteligencia Artificial (IA)

La integración de inteligencia artificial en el análisis de imágenes permite la automatización de procesos que anteriormente requerían la intervención manual. El hecho de que los ordenadores y softwares puedan aprender y tomar decisiones por ellos mismos, está cobrando vital importancia, ya que su uso y procesos se encuentra en auge en estos últimos años [27]. Los algoritmos de IA, previamente aprendidos, han demostrado mejorar la fiabilidad de la detección, aumentando así la confiabilidad de los resultados obtenidos. Además, la IA permite la integración de los datos térmicos con información proveniente de otras fuentes, creando un análisis intermodal que mejora el estudio global y la identificación precisa de defectos.

La implementación de la inteligencia artificial permite la detección en tiempo real de defectos constructivos, que lo hace crucial para la toma de decisiones en un periodo de tiempo reducido y para el monitoreo continuo. La transferencia de aprendizaje se ha convertido en una estrategia fundamental para mejorar el rendimiento y la eficacia en la detección de patologías en los edificios, adaptando algoritmos de IA aprendidos por un banco de imágenes visibles a un banco de imágenes térmicas, siempre más abundante el primero y siendo propicio aprender un algoritmo IA ya aprendido, aunque sea con imágenes de otra banda espectral, que un algoritmo IA que parte de cero. Gracias a la IA es posible transferir los conocimientos humanos a un procesador, aplicarle un proceso de aprendizaje y poder obtener resultados fiables y de una manera rápida y autónoma que facilite el trabajo y aumente la eficacia.

2.3.2 Teoría de las redes neuronales

El paradigma actual en el campo del aprendizaje profundo (*deep learning*), que es uno de los campos del aprendizaje automático (*machine learning*) que a su vez está dentro de la inteligencia artificial, se basa en el uso de un modelo computacional llamado red neuronal, diseñado para replicar el procesamiento de información del cerebro humano. Dentro de la inteligencia artificial, es uno de los modelos más empleados hoy en día.

Dentro del mecanismo de una red neuronal, las neuronas son el componente central de este enfoque de aprendizaje profundo, adoptando su nombre de las células del cerebro humano y replicando su funcionamiento en la transmisión de señales entre ellas. En términos algorítmicos, una neurona en el aprendizaje profundo se caracteriza por tres elementos principales: las entradas (I), los pesos (W) y una función de activación (σ) [28], tal y como se muestra en la Figura 2-11.

Las entradas representan los datos que las neuronas procesan al recibir información. Los pesos determinan la importancia relativa de estas entradas influyendo en la probabilidad de una hipótesis. La hipótesis, a su vez, es la función generada por la red neuronal para mapear las entradas y producir una salida específica, combinando y ponderando las entradas para encontrar posibles soluciones.

La función de activación es fundamental en el aprendizaje profundo, ya que define la salida de una neurona a partir de sus entradas y permite introducir no linealidades en el modelo, lo que facilita el aprendizaje de patrones complejos en los datos de entrada. Es esencialmente una función umbral que determina la salida de la neurona en función de su entrada.

En resumen, en el aprendizaje profundo, las redes neuronales se inspiran en el cerebro humano para procesar información, utilizando neuronas con entradas, pesos y funciones de activación para aprender y realizar predicciones sobre los datos de entrada, combinando y conectando las neuronas entre ellas en paralelo y/o en una serie de cadenas. La salida final del modelo será la predicción que realiza dicho modelo según el dato de entrada dado al inicio de este [29].

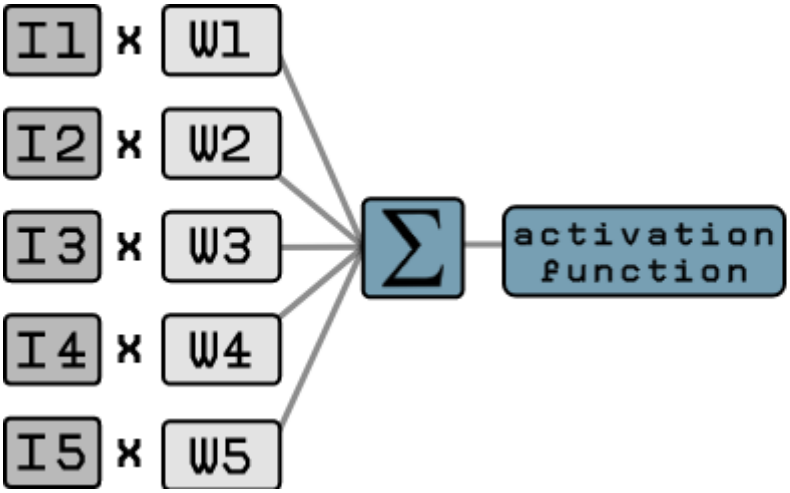


Figura 2-11 Funcionamiento simplificado de una neurona (Extraído de [30])

El objetivo de una neurona es ajustar los pesos basándose en muchos ejemplos de entradas y salidas durante su aprendizaje. En este sentido, la salida de una neurona se estima como una suma ponderada de las entradas "I" con sus respectivos pesos "W". El modelo simplificado de una neurona, para que esta se ajuste lo máximo posible a un entorno realista, necesita de un factor de sesgo. Este factor de sesgo, denotado como "b", que es el término de error constante, debe de estar en equilibrio con la varianza, que es el ratio en el que el error puede variar. De hecho, al tratarse de una constante, el factor de sesgo permite desplazar la función de activación hacia un lado del eje u otro. Una de las formas más sencillas de entender una red neuronal es a través del modelo de regresión lineal. Si toda operación que realiza una neurona se simplifica a este modelo, se puede considerar que el factor de sesgo "b" es el encargado de modificar el eje de ordenadas de una recta entre dos puntos [31].

Una vez explicado el concepto básico de una neurona, se puede extrapolar su funcionamiento a "n" neuronas distintas e interconectadas, permitiendo tomar la salida de una y utilizarla como entrada para la siguiente. De esta manera, quedaría conformada una red neuronal. Desde este punto, se comienza con el concepto de capas, existiendo la capa de entrada, capas intermedias u ocultas y la capa de salida, donde cada neurona de estas capas ocultas tiene un peso y un umbral asociado. Si el flujo de datos es enviado a la siguiente capa cuando la salida de cualquier neurona individual no tiene retorno, son denominadas *redes feedforward*, ya que las conexiones entre estas no forman un ciclo [32]. En cambio, si tras cada paso hacia delante entre capas, se realiza un paso hacia atrás para minimizar el error entre predicción y salida real, modificando los valores asignados en los pesos, son denominadas *redes backpropagation*, que son utilizadas para el aprendizaje de un modelo. Las redes neuronales también se pueden clasificar en redes superficiales o redes profundas. La diferencia entre una y otra radica en el número de capas ocultas, si una red neuronal consta de una sola capa oculta se la clasifica como red superficial, mientras que si cuenta con más de una capa oculta se le clasifica como una red neuronal profunda [33]. Hay que destacar que, en *deep learning*, todas las redes neuronales tienen dos o más capas ocultas siempre, dado que una se considera una red poco compleja y consecuentemente poca efectiva ante la resolución de casos con datos de entrada complejos, como son las imágenes térmicas.

2.3.3 Aprendizaje automático y profundo

El aprendizaje automático, en inglés *machine learning*, es uno de los principales campos en los que se centra la IA, tal y como se ha mencionado en el apartado previo. Consiste en un aspecto de la informática en la que los ordenadores disponen de la capacidad de aprender a pesar de no estar programados para ese fin. Así, m*achine learning* utiliza algoritmos para aprender con la información que le es proporcionada.

En el campo del aprendizaje automático existen principalmente tres vertientes, siendo estas el aprendizaje supervisado, no supervisado y el reforzado [34], tal y como se muestra en la Figura 2-12.

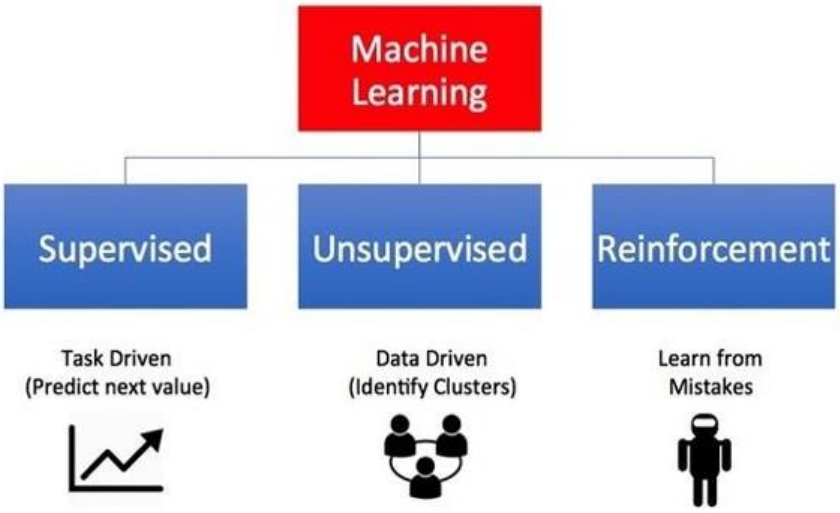


Figura 2-12 Vertientes del aprendizaje automatizado (Extraído de [35])

- **Aprendizaje supervisado:** Es una metodología en la que un sistema aprende proporcionándole etiquetas o valores de salida a los diferentes datos de entrada que debe predecir. Así, durante el aprendizaje, el sistema compara su error/desviación con respecto a los valores reales de las salida, reajustándose en la siguiente iteración/intento de predicción (*epoch*) del transcurso del aprendizaje con la introducción de nuevo de los datos de entrada.
- **Aprendizaje no supervisado:** Es una metodología que se utiliza para resolver problemas en los cuales existe poca o ninguna información sobre cómo podrían ser los resultados de los datos de entrada. En este enfoque, el sistema analiza las características que posee el objeto sometido a estudio, extrayendo las propiedades que considera útiles del conjunto de datos.
- **Aprendizaje reforzado:** Es una estrategia que se fundamenta en premiar los comportamientos deseables y castigar aquellos no deseados mientras un sistema aprende, permitiendo la interacción con este, resultando en retroalimentación obtenida a través del proceso de ensayo y error. Se basa en conceptos de los dos aprendizajes previos, siendo el más complejo y completo.

El aprendizaje profundo, en inglés *"deep learning"* (DL), ha experimentado una evolución notable gracias a la continua emergencia de nuevos modelos de DL desde principios del siglo XXI. En comparación con otros métodos de aprendizaje de Inteligencia Artificial (IA), los modelos DL presentan una gran mejora en la resolución de problemas que requieren análisis altamente automatizado. Esto se debe principalmente al hecho de que los modelos DL permiten que el ordenador realice una tarea asignada de manera autónoma después de un proceso de entrenamiento.

Deep learning proviene del *Machine Learning* (ML) anteriormente mencionado. La ventaja de los modelos DL en comparación con los modelos ML tradicionales proviene del proceso de extracción de características. Este proceso de extracción de características se desarrolla de manera autónoma en los modelos DL, a diferencia del proceso de extracción de características en los modelos ML tradicionales, que es más complejo y requiere un conocimiento previo más detallado del dominio del problema antes de la extracción [36].

Los modelos de aprendizaje profundo, específicamente las redes neuronales convolucionales (CNN), por sus siglas en inglés *Convolutional Neural Network*, están diseñados específicamente para capturar y aprender patrones complejos dentro de las imágenes. Pueden aprender desde características de nivel básico, como bordes y texturas, hasta el más alto nivel, donde son capaces de aprender conceptos

y categorías dentro de las imágenes [28]. En resumen, una CNN permite el aprendizaje automático de características relevantes tomando como base los datos, y sin necesidad de una ingeniería de características específicas. Las CNN están basadas en la teoría explicada en el apartado previo.

La automatización de la interpretación de imágenes térmicas elimina la subjetividad y la dependencia de la experiencia del investigador a la hora de realizar un estudio termográfico. Como consecuencia, ya existen varios estudios recientes que muestran el potencial del uso de modelos DL aplicados a medidas obtenidas por la termografía infrarroja, superando las limitaciones mencionadas anteriormente. Existen varios trabajos para tareas de clasificación y predicción en el campo de la infraestructura, concluyendo que la automatización de los resultados termográficos haciendo uso de redes neuronales puede ser de gran utilidad en la detección de defectos constructivos. En estos trabajos se centra el apartado siguiente.

2.4 La termografía en los edificios

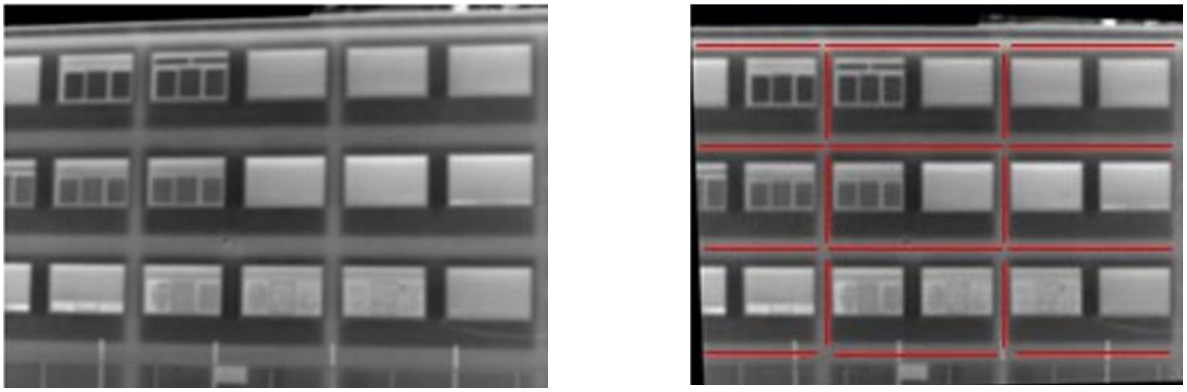
La termografía infrarroja es una técnica no destructiva utilizada para la evaluación del estado de un edificio. Es una técnica rápida, fiable, que no requiere la intervención directa en la construcción y que hace posible localizar el deterioro de los materiales constructivos [37]. Tal y como se puede apreciar en la Figura 2-13, gracias a la termografía infrarroja, se pueden detectar las diferencias de temperatura en el edificio sometido a estudio que pueden estar relacionadas con patologías existentes, a pesar de que a simple vista pueda parecer que no existe ninguno.



Figura 2-13 Termografía aplicada a edificios (Extraído de [38])

A pesar de que la aplicación de la termografía infrarroja (IRT) no era muy común hasta estos últimos años, su uso está en continuo crecimiento. Prueba de ello, es la existencia de diferentes estudios que contemplan el análisis de los materiales empleados en la construcción de infraestructuras tales como asfalto, metales, hormigón etc. Las primeras aplicaciones de la IRT en infraestructuras civiles fueron dentro del campo aeronáutico debido a la gran exigencia de esta industria. Actualmente, dentro de los trabajos de IRT más recientes, se puede destacar el de Danielski y Fröling [39], que presenta un método cuantitativo utilizando IRT pasiva para medir el coeficiente global de transferencia de calor de envolventes de edificios sometidos a un flujo de calor en estado no estacionario. Por su parte, Tejedor et al. [40] también calculan el coeficiente global de transferencia de calor utilizando IRT cuantitativa para paredes de hojas múltiples en modo pasivo, pero en este caso bajo condiciones de estado estacionario.

En el caso de las patologías, debido a sus valores de temperatura anómalos en comparación con el entorno no alterado, la IRT es una técnica adecuada para la detección y posterior cálculo de algunas de sus propiedades termofísicas. Hay varios estudios de IRT relacionados con el análisis de puentes térmicos debido a su gravedad en los edificios, tal y como se ha comentado en apartados previos. En este contexto, Garrido et al. [41] proponen un método para la detección automática de puentes térmicos en diferentes fachadas de edificios, y el cálculo automático de su transmitancia térmica lineal, con un enfoque en modo pasivo, tal y como se puede observar en la Figura 2-14.



a) **b)**

Figura 2-14 Detección de puentes térmicos en fachadas a) imagen original, b) imagen con los puentes térmicos localizados (extraído de [41])

Otra de las patologías más importantes es la humedad, como también se ha citado en apartados previos, para la cual Edis et al. [42] prueban un enfoque cuasi-cuantitativo para identificar la humedad ascendente en una fachada de cerámica adherida, mediante la comparación de tres técnicas diferentes de procesamiento de imágenes térmicas, incluyendo el análisis de componentes principales, en inglés *Principal Component Analysis* (PCA), y en modo pasivo. Una tercera patología es la infiltración de aire, que puede representar entre el 10 % y el 50 % de la demanda energética de los edificios. A este respecto, el trabajo conducido por Lerma et al. [43] evalúa el potencial de la IRT activa en enfoques tanto cualitativos como cuantitativos, para poder detectar puntos de fuga de aire dentro de una habitación.

Normalmente, la inspección de edificios requiere la operación manual de la cámara térmica e interpretación de las imágenes térmicas para detectar la pérdida de calor, pero en los últimos años se están realizando estudios empleando métodos más automáticos. Tal y como demuestra la investigación presentada por Martínez de Dios y Ollero, se puede utilizar un Vehículo Aéreo No Tripulado (UAV) para la inspección de edificios. Dicho sistema es capaz de detectar automáticamente la pérdida de calor en las ventanas [44]. Existen también otros sistemas que transforman de manera autónoma las imágenes térmicas a un modelo 3D, eliminando las ventanas y las puertas y detectando regiones con alta pérdida de calor en la fachada. En la literatura también se pueden encontrar trabajos que proponen un sistema térmico para detectar infiltraciones de aire en el techo, tal y como se puede apreciar en la Figura 2-15 [45].

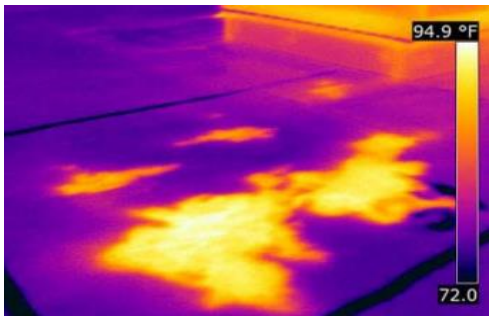
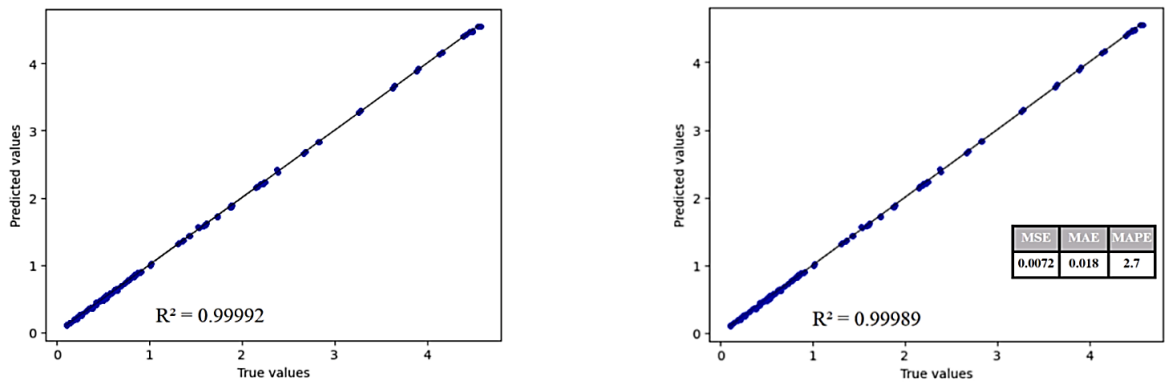


Figura 2-15 Imagen térmica de infiltraciones de aire en el techo (extraído de [45])

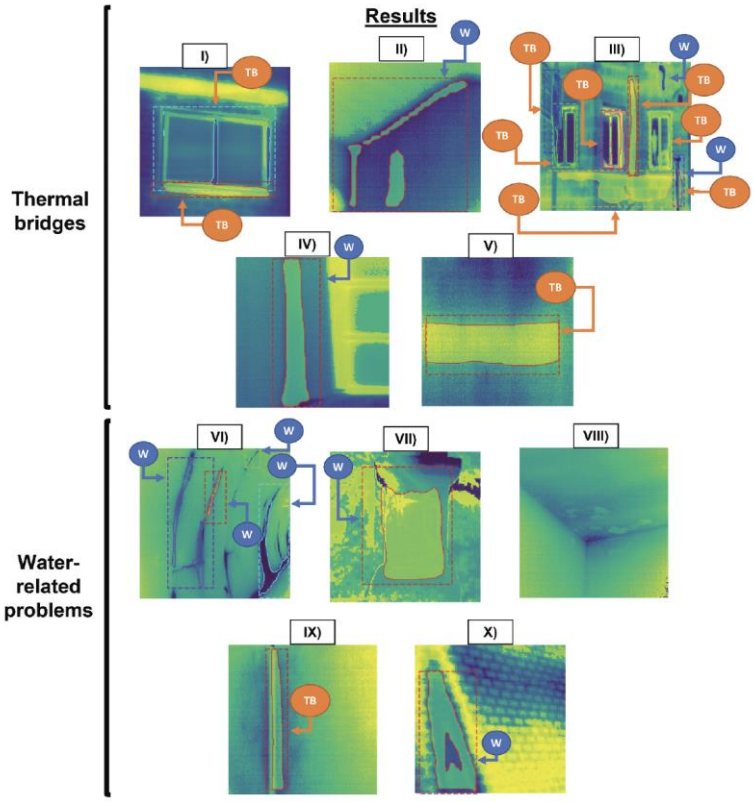
En los últimos tiempos, se han desarrollado nuevas formas rápidas y efectivas para procesar el contenido de las imágenes térmicas. Existen estudios donde se presentan modelos de redes neuronales para la identificación de deficiencias en un conjunto de datos de imágenes térmicas de edificios, haciendo posible que investigadores poco especializados en ciencia de datos sean capaces de obtener resultados con una alta precisión [46]. Cada vez son más las aportaciones que se pueden encontrar relacionadas en este campo, como por ejemplo el trabajo de Dafico et al. [47], que recogen el estudio para predecir el contenido de humedad de los materiales según su temperatura superficial a través de modelos de aprendizaje automático, utilizando como entrada el material (su temperatura) y las condiciones ambientales. Los resultados de este trabajo mostraron que los modelos neuronales presentan un coeficiente de determinación superior a 0,96 y un error menor al 5% (véase Figura 2-16).



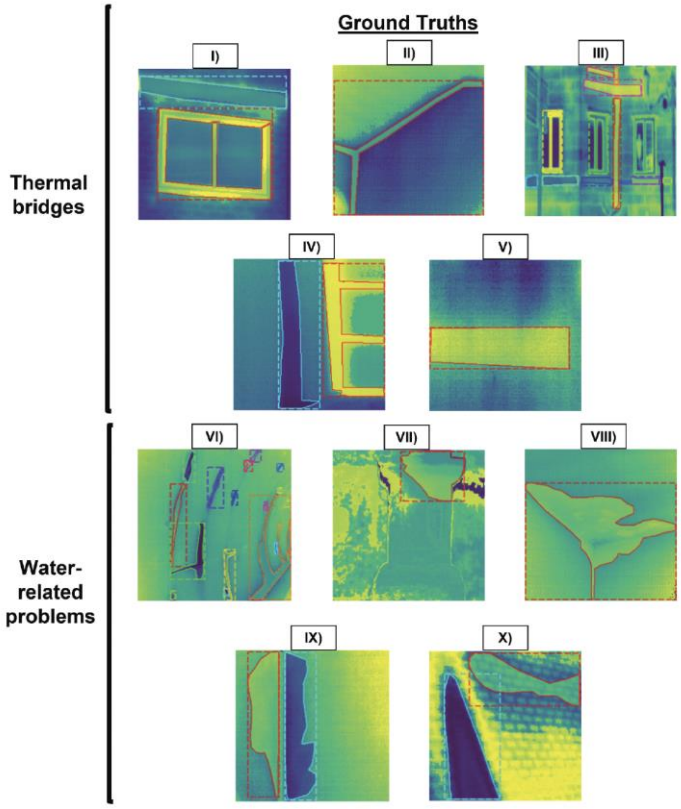
a) **b)**

Figura 2-16 Uno de los resultados obtenidos con uno de los modelos DL, a) en los datos de entrada usados en el aprendizaje, b) en datos no empleados para el aprendizaje del modelo (extraído de [47])

Asimismo, se han realizado estudios utilizando *deep learning* en imágenes térmicas de infraestructuras con problemas relacionados con el agua (humedad) y puentes térmicos. En este caso, Garrido et al. [48] usando una red neuronal a partir de las salidas de un algoritmo de preprocesamiento como conjunto de datos de entrada, para detectar, segmentar y clasificar automáticamente cada área defectuosa. En varios casos de estudio, el modelo DL ha ofrecido valores de métricas de prestación mayores al 50 % (véase Figura 2-17).



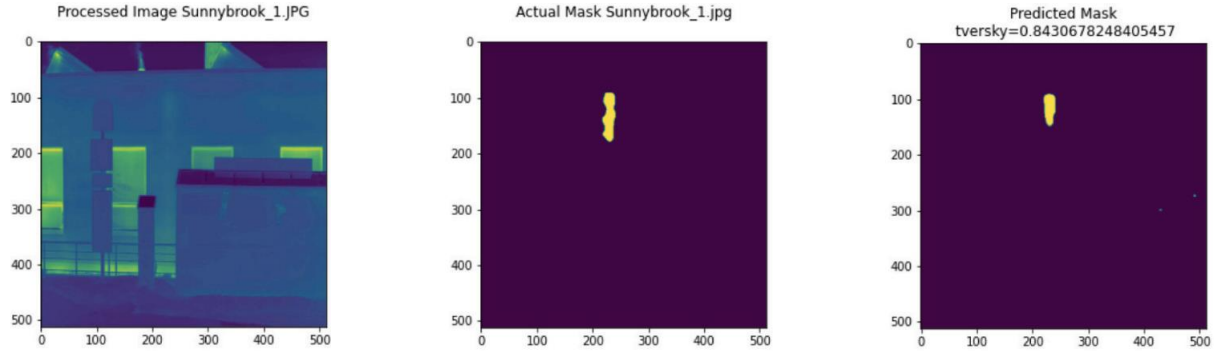
a)



b)

Figura 2-17 a) Predicciones obtenidas tras el aprendizaje del modelo ("W" significa humedad, "T" significa puente térmico). b) Referencia de las áreas reales de cada defecto en las imágenes térmicas de testeo, es decir, no usadas en el aprendizaje del modelo (extraído de [48])

Por otra parte, Gertsvolf et al. [46] presentan el desarrollo de un novedoso modelo CNN para la identificación de áreas deficientes que resultan en una pérdida potencial de energía sobre un conjunto de datos de imágenes térmicas de envolventes de edificios a partir de UAVs. El objetivo fue segmentar e identificar con precisión la pérdida de energía en cualquier imagen térmica. El coeficiente de testeo fue de un 43 % de precisión en la segmentación de regiones en comparación con las máscaras creadas manualmente. Ese porcentaje para una investigación inicial es fuerte y muestra el potencial que ofrece el DL para esta estrategia de evaluación (véase Figura 2-18).



a) **b)** **c)**

Figura 2-18 Uno de los (c) resultados con mayor precisión (84,3 %) obtenido. a) es la imagen térmica de entrada y b) la referencia del defecto (extraído de [46])

El empleo de esta tecnología requiere comprender los principios básicos de la transferencia de calor por radiación. Así, con las imágenes térmicas obtenidas mediante una cámara termográfica es posible identificar problemas en una etapa temprana, lo que permite que se evalúen y corrijan antes de que se vuelvan más graves y costosos de reparar. Es importante destacar que la envolvente del edificio desempeña un papel fundamental en su rendimiento térmico, ya que a través de él se produce la interacción entre el entorno exterior y el interior. Si la envolvente está bien aislada térmicamente, no hay grandes pérdidas de calor y los costos energéticos de climatización son menores. Defectos como los puentes térmicos pueden contribuir significativamente a un aumento en los costos energéticos, pero también provocan heterogeneidades en la temperatura superficial, condensaciones superficiales y tienen un impacto importante en la comodidad del usuario del edificio. Asimismo, la demanda energética puede ser también afectada por infiltraciones de aire, humedad y grietas, las cuales provocan un aumento de la transmitancia térmica de la envolvente de un edificio junto con los puentes térmicos. Por último, la termografía infrarroja no solamente es utilizada como método de detección de defectos constructivos, sino también puede presentar otras aplicaciones como las que se exponen a continuación [49]:

- Inspección de instalaciones y equipamientos
- Evaluación de la eficiencia energética
- Monitoreo de estructuras
- Investigación en condiciones adversas
- Integración con tecnologías emergentes

3 DESARROLLO DEL TFG

En este capítulo se describe en detalle el trabajo realizado durante el transcurso de este TFG. Se comenzará con una contextualización del caso de estudio, brindando una descripción en detalle del edificio objeto de investigación, incluyendo su ubicación y distribución, así como los efectos meteorológicos a los que está expuesto dicho edificio. Además, se detallan los equipos utilizados para la captura de imágenes, los cuales comprenden tanto una cámara de alta gama, como una cámara de bajo coste, *low cost*.

Posteriormente, se expone la metodología adoptada para la adquisición y etiquetado de las imágenes térmicas para el aprendizaje del modelo DL. Se describe los procedimientos seguidos para garantizar la calidad y coherencia de los datos recopilados, así como las técnicas utilizadas para la identificación y clasificación de las patologías presentes en el edificio objeto de estudio.

Por último, se aborda el proceso de desarrollo y aprendizaje de la red neuronal diseñada para automatizar la detección y clasificación de las diversas patologías, describiendo las etapas de diseño del modelo, la selección de parámetros pertinentes, así como la preparación y procesamiento de los datos de entrada.

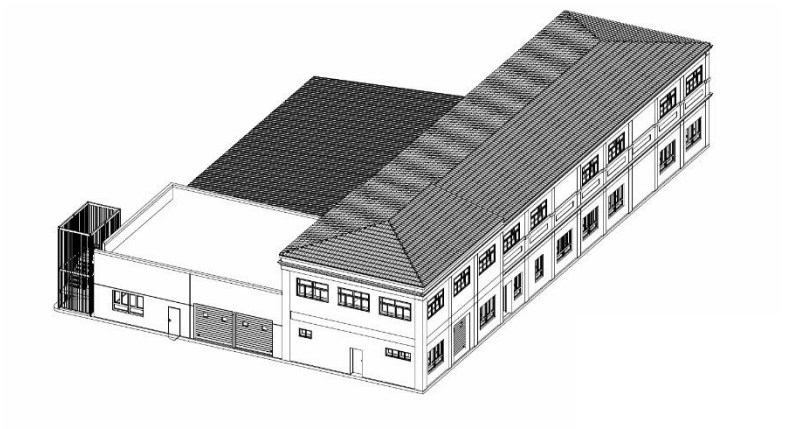
3.1 Contexto del caso de estudio

El estudio realizado se ha centrado en el Edificio de Investigación existente en el CUD-ENM, inaugurado en el año 2018, que desempeña un papel fundamental al proporcionar a la institución el espacio necesario para llevar a cabo diversas tareas de investigación por parte del profesorado y alumnado presentes en el Centro [50].

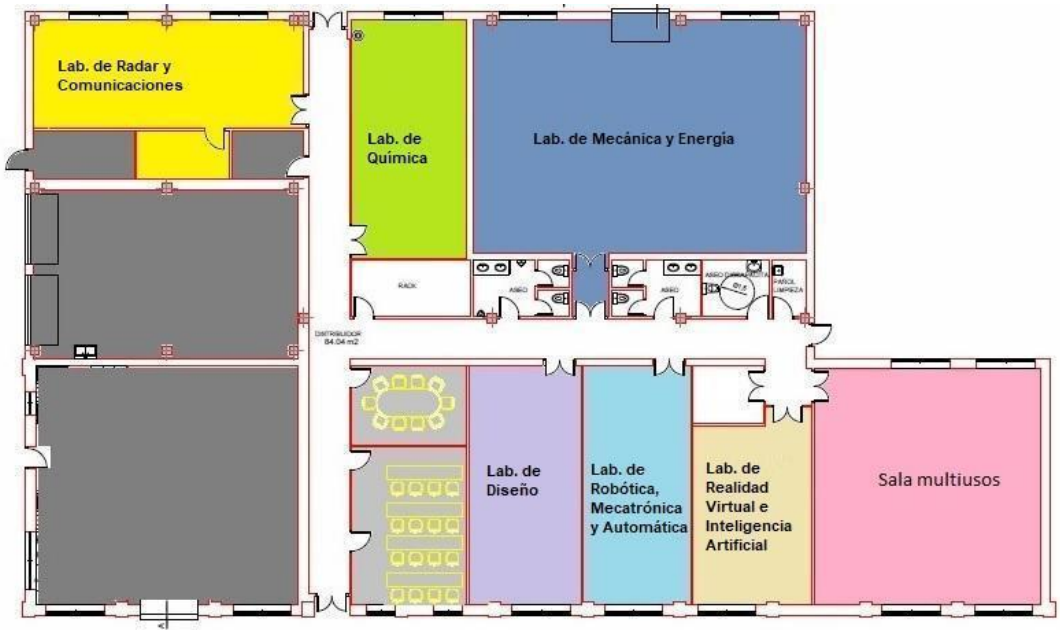
Dotado de modernas instalaciones, el edificio alberga una variedad de laboratorios y salas totalmente acondicionadas y equipadas, que facilitan la realización de diversas actividades de investigación en el Centro. A continuación, se enumeran los diferentes laboratorios de los que está dotado en la actualidad:

- Laboratorio de Radar y Comunicaciones
- Laboratorio de Química
- Laboratorio de Mecánica y Energía
- Laboratorio de Diseño
- Laboratorio de Robótica, Mecatrónica y Automática
- Laboratorio de Realidad Virtual e Inteligencia Artificial

Además de estos laboratorios, el edificio cuenta con 2 salas, estando una de ellas destinada a la realización de reuniones, mientras que la otra, de dimensiones inferiores a la anterior, está dedicada al almacenaje de equipamiento. A su vez, el edificio cuenta también con 2 baños. Una imagen del citado edificio, así como de la distribución de los laboratorios y salas, se puede observar en la Figura 3-1.



a)



b)

Figura 3-1 Edificio de investigación CUD-ENM. a) Vista general. b) Plano primera planta (Extraído de [50])

El edificio objeto de estudio se encuentra estratégicamente ubicado en las proximidades del muelle "Almirante Vierna", lo que lo expone directamente a los vientos de poniente, que traen consigo precipitaciones habituales en la zona de las "Rías Baixas" durante el invierno, y buena parte del otoño y primavera. La climatología de esta región se convierte en un factor determinante en la aparición de posibles defectos en la construcción. La zona de Pontevedra se caracteriza por un clima oceánico, con una media de 137 días de lluvia al año, una temperatura anual promedio de 17 grados centígrados, una humedad relativa media del 81 % y un índice ultravioleta de 4 [51].

Teniendo en cuenta todos estos factores, así como la ubicación del edificio de investigación en la línea costera, expuesto y sin resguardo frente a las condiciones meteorológicas adversas, se pueden anticipar ciertas patologías como las siguientes:

- **Humedad:** La cercanía al mar en el noroeste peninsular conlleva niveles elevados de humedad durante todo el año, lo que podría dar lugar a problemas de humedad en las estructuras del edificio.
- **Corrosión:** La exposición prolongada a la salinidad del ambiente marino puede provocar corrosión en estructuras metálicas y de hormigón armado, especialmente en aquellas ubicadas en áreas cercanas al mar.
- **Variaciones térmicas:** Durante el otoño y la primavera se experimentan cambios bruscos de temperatura en un corto periodo de tiempo, pasando de temperaturas moderadas de 10-15 ºC a temperaturas más cálidas de entre 25 y 30 ºC. Estas variaciones térmicas pueden ejercer tensiones sobre los materiales de construcción, lo que podría contribuir a la aparición de grietas o deformaciones en el edificio.

A continuación, en la Figura 3-2 se muestra la ubicación de este edificio sobre un mapa general de la ría de Pontevedra (Figura 3-2 a), y otra de la zona en la que se encuentra ubicada dentro de la Escuela Naval Militar (Figura 3-2 b).



a) **b)**

Figura 3-2 Situación geográfica del edificio de investigación en: a) Ría de Pontevedra (círculo amarillo), y en b) Escuela Naval Militar (rectángulo amarillo) (Elaboración propia usando Google Maps)

Para la adquisición de imágenes térmicas, se emplearon dos cámaras termográficas de la reconocida marca FLIR: La FLIR E85, que representa la opción de alta gama, y la FLIR ONE EDGE, una alternativa de bajo coste (*low cost*).

La FLIR E85 se distingue por ser una cámara termográfica de alta resolución diseñada específicamente para aplicaciones profesionales que requieren de una precisión excepcional en la detección de problemas térmicos. Equipada con un sistema de enfoque automático y pantalla táctil, ofrece al usuario un empleo intuitivo y práctico. Además, viene acompañada de una serie de accesorios, como dos baterías, estuche de transporte rígido, tarjeta SD de 8 GB, cables USB, entre otros, lo que la convierte en una herramienta completa y versátil para el trabajo en campo [52]. En la Figura 3-3 se puede observar el modelo utilizado para la realización del trabajo.



Figura 3-3 Cámara FLIR E85 (Extraído de [53])

Por otro lado, la FLIR ONE EDGE es una cámara termográfica más compacta y accesible que se conecta de manera inalámbrica a los smartphones para su funcionamiento. Esta característica permite la inspección de objetos fuera del alcance visual directo, y proporciona la capacidad de poder operar la cámara con una sola mano. Es compatible con dispositivos Android e iOS, y todas las imágenes y vídeos capturados se guardan directamente en el teléfono móvil del usuario. Además, su funcionalidad para cargar instantáneamente los archivos en la nube agiliza significativamente el posterior procesamiento de las imágenes térmicas, mostrándose a continuación una imagen de la citada cámara en la Figura 3-4 [54].



Figura 3-4 Cámara FLIR ONE EDGE (Extraído de [55])

A continuación, se presenta en la Tabla 3-1 un cuadro resumen que detalla las características principales de ambas cámaras, lo que permitirá realizar una comparativa precisa de sus prestaciones:

Características	FLIR E85	FLIR ONE EDGE
Resolución térmica	384 × 288 (110,592 píxeles)	80 × 60 (4800 píxeles)
Rango de temperaturas del objeto	De -20 °C a 1200 °C	De -20 °C a 120 °C
Precisión	±2 °C o ±2 % de lectura, para temperatura ambiente de 15 °C a 35 °C y temperatura del objeto superior a 0 °C	±3 °C o ±5 %. Aplicable 60 segundos después del inicio cuando la unidad está entre 15 °C y 35 °C y la escena está entre 5 °C y 120 °C
Enfoque	Medidor de distancia láser continuo de un disparo Contraste de un disparo Manual	30 cm fijo - Infinito
Sensibilidad térmica	<40 mK a 30 ºC	70 mK
Campo de visión	42° x 32° (lente de 10 mm), 24° x 18° (lente de 18 mm), 14° x 10° (lente de 29 mm)	54° ± 1° x 42° ± 1°
Banda espectral	*Long-wavelength infrared* (LWIR)	*Long-wavelength infrared* (LWIR)
Modos de imagen	Infrarrojos Visual MSX Imagen en imagen	Infrarrojos Visual MSX
Almacenamiento	Tarjeta SD extraíble (8 GB)	Teléfono móvil
Precio	≈ 10000€	400-500€

Tabla 3-1 Características cámara FLIR E85 y FLIR ONE EDGE (Elaboración propia)

3.2 Zonas estudiadas

Para la preparación de la captura de imágenes térmicas de las diversas patologías existentes en el edificio, se elaboró un plano en el que se identifican y enumeran todas las áreas donde se observaron visualmente o fue detectada la presencia de las patologías descritas en secciones anteriores.

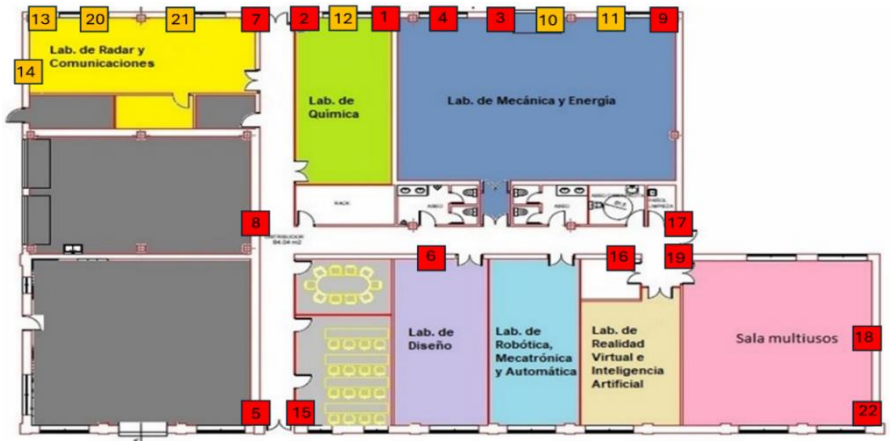
Se identificaron diferentes patologías, desde puentes térmicos pasando por humedad, filtración de aire y grietas, estando la mayoría concentradas en la fachada oeste del edificio de investigación. Esta fachada se encuentra expuesta a los vientos predominantes del poniente y a las salpicaduras del agua del mar al romper contra el muelle, lo que sugiere una clara tendencia a la aparición de defectos en las zonas más expuestas a los efectos meteorológicos.

En cuanto a la distribución de las imágenes térmicas capturadas en la primera planta, la mayoría corresponden a los laboratorios de química y mecánica. Esto se debe a que dichos laboratorios están ubicados en la fachada oeste del edificio, donde se concentran la mayor parte de las patologías. Además,

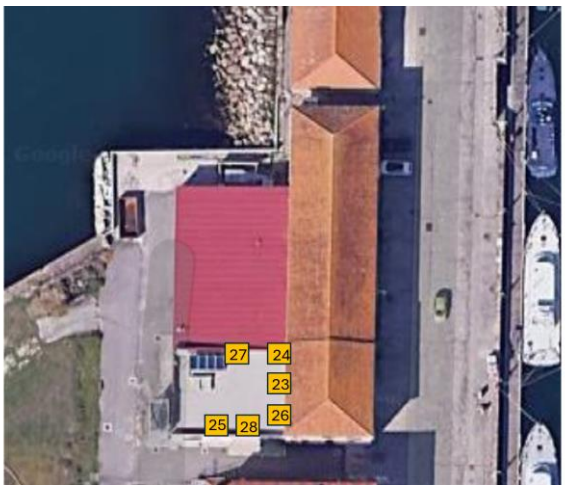
se encontraron numerosas patologías en los pasillos, debido a su contacto directo con el exterior y a la circulación de aire que se genera cuando se abren una o más puertas.

Por otro lado, en la segunda planta se adquirieron imágenes térmicas del patio existente en esta, estando el interior de esta planta ocupado por la banda de música de la ENM, lo que queda fuera del alcance del presente estudio.

En la Figura 3-5 se muestra la localización de las patologías encontradas en la primera planta, y las correspondientes capturas de imágenes térmicas, mientras que en la Figura 3-6 se presentan las ubicadas en la segunda planta. Cabe destacar que en la misma localización puede que haya más de una patología, por tanto, capturando más de una imagen térmica en la misma zona. Por otro lado, en la Figura 3-5, se muestran en rojo las patologías existentes en el interior del edificio, mientras que en naranja se identifican aquellas ubicadas en la parte exterior del mismo. En cambio, en la Figura 3-6, al sólo existir defectos en el exterior del edificio, se marcan únicamente en naranja. Estos mapas proporcionan una visualización clara de la distribución espacial de las patologías identificadas, con el propósito de facilitar su análisis y posterior tratamiento.



a)



b)

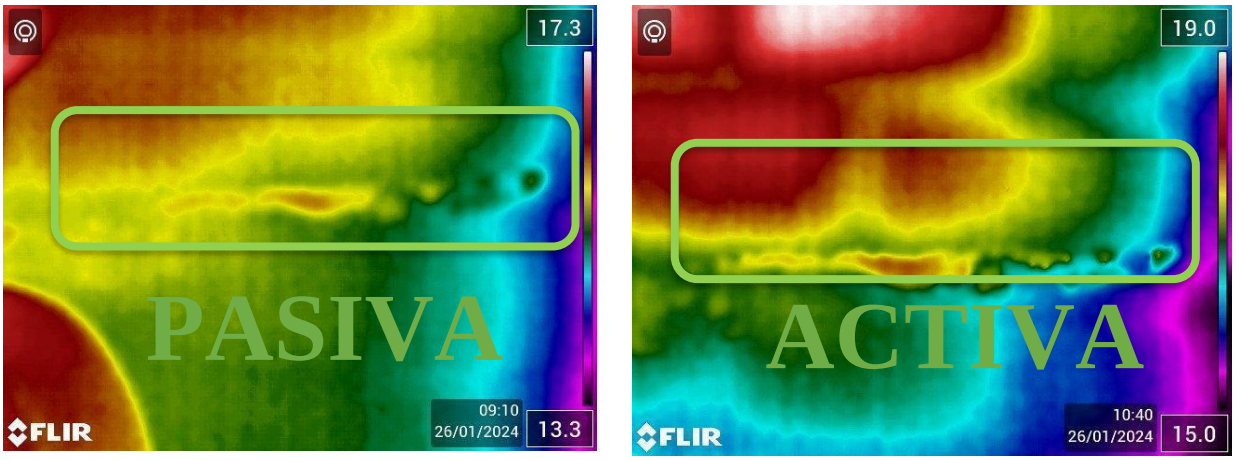
Figura 3-5 Numeración de las zonas con patologías estudiadas: a) en la primera planta, b) en la segunda planta (Elaboración propia)

3.3 Metodología de adquisición de imágenes térmicas

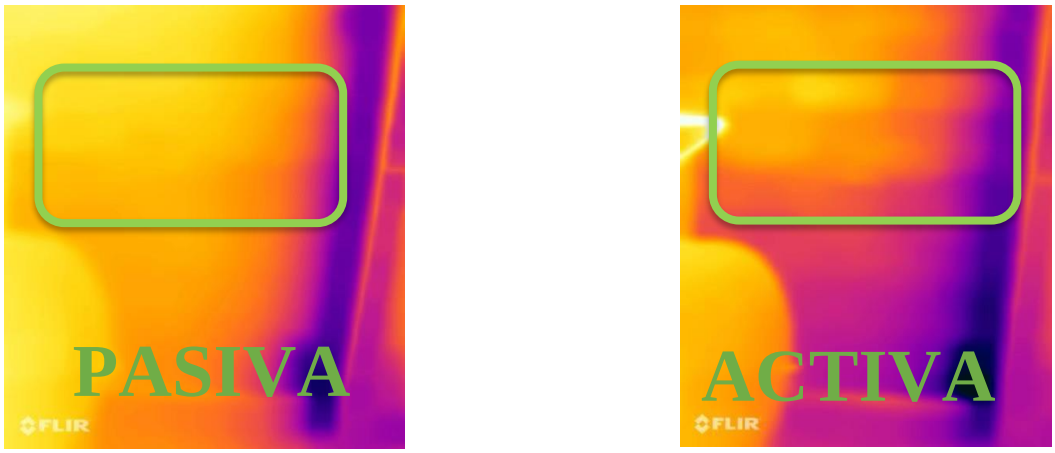
En un primer lugar, se inspeccionó visualmente el edificio, ya que muchos de los defectos eran claramente diferenciables a simple vista, tales como grietas o humedades en un estado de degradación avanzado. Posteriormente, se hizo un recorrido analizando con la cámara termográfica cada una de las paredes, techos y suelos del edificio. Gracias a este segundo recorrido, fue posible identificar pequeñas zonas con diferente valor térmico al resto de la superficie, que adelantaba la existencia de otra patología en ese lugar.

A la hora de capturar imágenes térmicas, en cada uno de los defectos se empleó para la captura ambas cámaras termográficas (la de alta gama y la de bajo coste). En el interior del edificio, se realizó una imagen térmica de cada patología de forma activa y pasiva, empleando para la primera un foco halógeno para calentar la superficie, con una duración del calentamiento de 5 minutos como máximo, dejando luego enfriar 2-3 minutos para evitar la huella térmica dejada por la propia lámpara. En cuanto al exterior del edificio, no fue posible capturar las imágenes térmicas de forma activa por razones logísticas, ya que el foco halógeno precisa de corriente eléctrica para su funcionamiento y no era posible el suministro de la misma a ciertas partes de la fachada. Con las adquisiciones en pasiva y en activa, se duplica el banco de imágenes térmicas como dato de entrada a la hora de aplicar el proceso de aprendizaje al modelo DL seleccionado.

En cuanto a la captura de imágenes térmicas de manera pasiva, se trata de un proceso sencillo en el que únicamente es necesario realizar simultáneamente dos imágenes térmicas con ambas cámaras termográficas. En el caso de la captura activa, tal y como se ha comentado previamente, se calentaba previamente la zona de interés con el foco halógeno durante aproximadamente 5 minutos, seguido de un periodo de enfriamiento de aproximadamente 2-3 minutos antes de tomar las imágenes térmicas. Como se puede observar en la Figura 3-6, la diferencia existente entre una imagen térmica tomada de forma activa o pasiva es notable a la hora de identificar con mayor precisión los defectos constructivos, ya que el grado de detalle tras estimular con la lámpara halógena a la superficie del edificio es mucho mayor.



a)

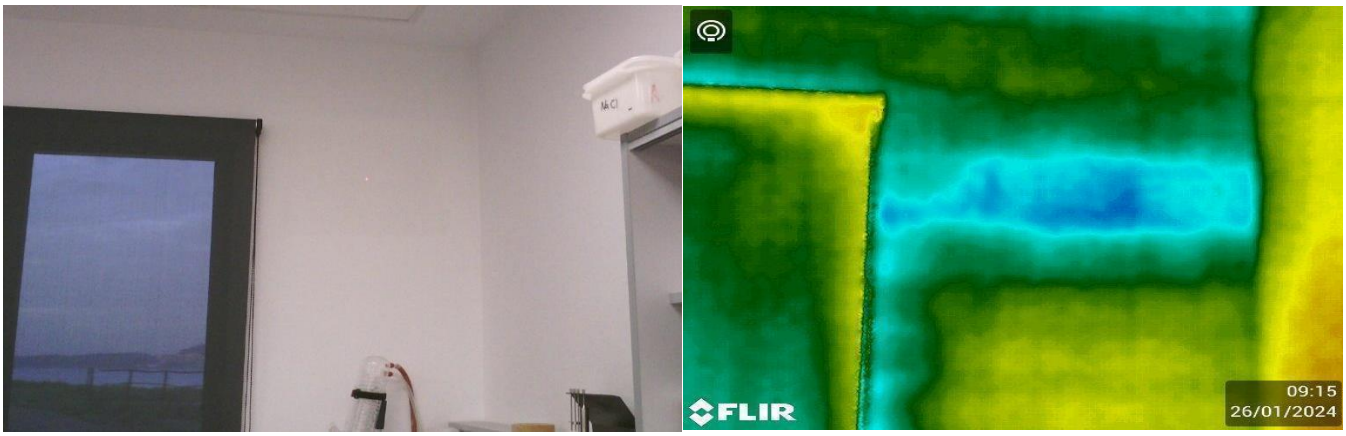


b)

Figura 3-6 Comparativa imagen térmica pasiva y activa: a) FLIR E85, b) FLIR ONE EDGE. Los recuadros insertados indican la localización de los defectos (a) grieta, b) humedad) (Elaboración propia)

En la Tabla 3-2 se presenta las patologías que han sido ámbito de estudio, entre las que se encuentran humedades, filtraciones de aire, grietas, y puentes térmicos. Estas imágenes térmicas han sido capturadas utilizando las diferentes cámaras para proporcionar una visión completa y detallada de los defectos identificados. En primer lugar, se han incluido las imágenes tomadas con la cámara visible, que permite obtener una visualización directa de las características superficiales de las patologías. Por otro lado, se han agregado las mismas imágenes, pero obtenidas a través de las 2 cámaras termográficas con las que se ha realizado el estudio, la FLIR E85 y la FLIR ONE EDGE. La primera, de alta gama, ofrece una gran resolución y precisión en la detección de objetos, facilitando la identificación de patologías ocultas a simple vista. La segunda, de bajo coste, aunque tiene una resolución más limitada en comparación con la FLIR E85, sigue siendo una herramienta valiosa para la detección rápida de defectos constructivos, proporcionando otra perspectiva térmica y complementando las imágenes visibles y térmicas obtenidas con la otra cámara. Esto se verá con detalle en el Apartado 4 al analizar los resultados del trabajo.

Tras la Tabla 3-2, en la Figura 3-7 se muestra un ejemplo de una patología no identificable para el ojo humano, y en la Figura 3-8 otra que sí se aprecia visiblemente. El de la Figura 3-7 a) se trataba de una humedad de tamaño considerable en el laboratorio de química, que no es identificable a simple vista, pero sí se puede diferenciar con la cámara térmica (Figura 3-7 b). El de la Figura 3-8 se trata de una grieta en el techo del pasillo principal, también de grandes proporciones, en la que no es necesario utilizar la termografía infrarroja para poder detectarla.



a) **b)**

Figura 3-7 Humedad en el laboratorio de química no identificable a vista humana en cámara digital (a), pero sí en la cámara térmica (región azul) (b) (Elaboración propia)

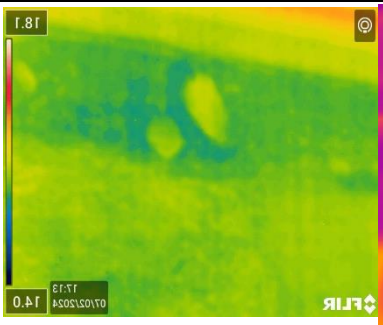
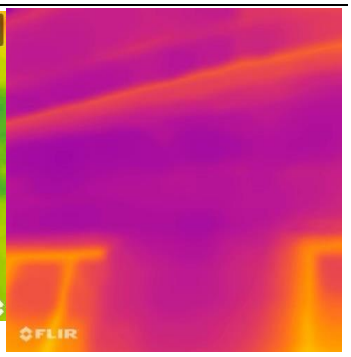
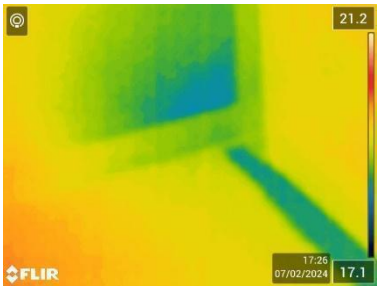
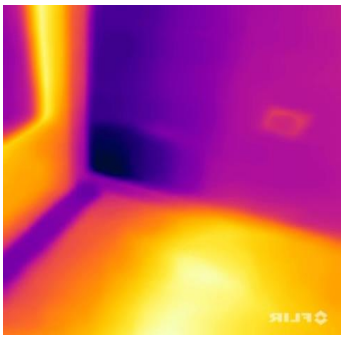
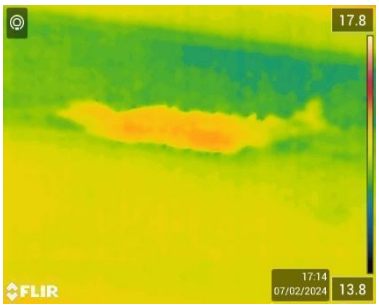
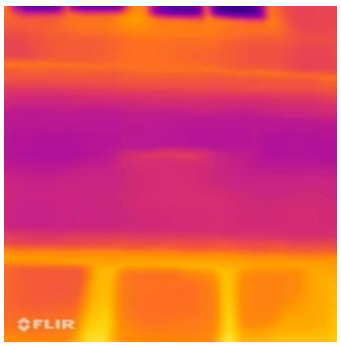
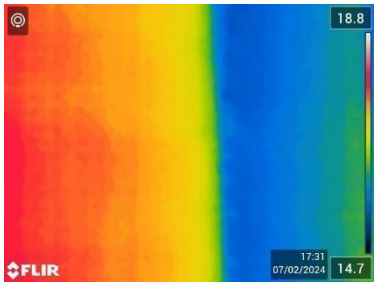
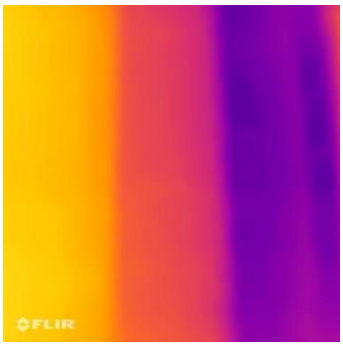
	Visible	FLIR E85	FLIR ONE EDGE
Humedad			
Filtración de aire			
Grieta			
Puente térmico			

Tabla 3-2 Comparativa de las patologías según tipo de imagen (Elaboración propia)

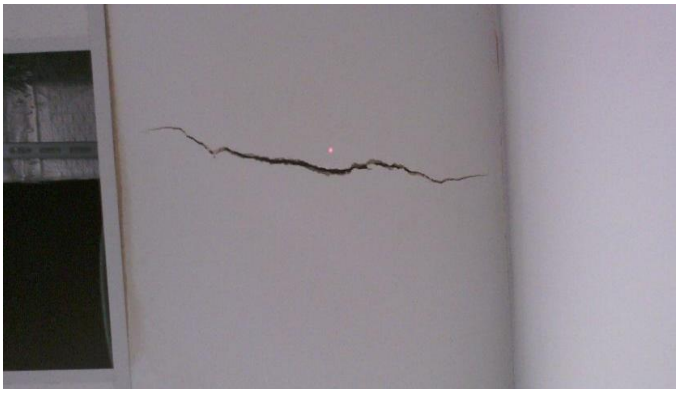


Figura 3-8 Grieta en el techo del pasillo principal del laboratorio (Elaboración propia)

Finalmente, para el almacenaje de las imágenes térmicas, la cámara FLIR E85 dispone de una tarjeta de memoria donde se van almacenando todas ellas. Para poder traspasar estas imágenes de la tarjeta de memoria al ordenador es necesario un lector de tarjeta SD permitiendo así su almacenamiento en el ordenador para su posterior edición. La cámara FLIR ONE EDGE utiliza una aplicación que se instala en el propio teléfono móvil, por lo que pasar estas imágenes es mucho más sencillo, ya que se puede hacer de diferentes maneras como compartirlas vía e-mail o descargarlas a través del navegador del ordenador, ya que todas estas imágenes de la cámara *low cost* se suben de manera automática a la nube del usuario de la cámara.

3.4 Etiquetado de las imágenes térmicas

El etiquetado de las imágenes térmicas se realizó siempre de la misma manera, y consistía en la inclusión de unos parámetros que se explica a continuación. No obstante, se destaca antes de la explicación del etiquetado, el nombre definido a cada una de las imágenes tomadas para una correcta gestión de cada una.

- **Cámara**: FLIR E85 o FLIR ONE EDGE
- **Fecha**: Únicamente mes y día sin espacios (ej.: 0802; se correspondería al 8 de febrero)
- **Hora**: Hora a la que se tomó la imagen térmica (ej.: 1800)
- **Numeración**: Para identificar la zona donde fue tomada la imagen, que va del número 1 al 28
- **Método adquisición**: Activo o pasivo, ACT o PAS respectivamente

En la Figura 3-9 se muestra un ejemplo en cómo se definiría una imagen térmica en concreto. En este caso, imagen capturada por la cámara FLIR E85, el día 8 de febrero, a las 18 horas, en la zona 9 y en pasiva.

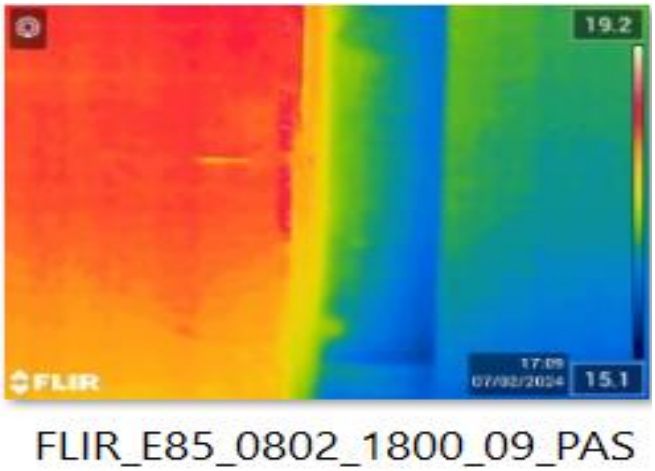


Figura 3-9 Ejemplo de nomenclatura de las imágenes térmicas (Elaboración propia)

En cuanto al proceso de etiquetado, cada región patológica de cada imagen térmica está trazada por el software VGG Image Annotator (VIA) [56] dada su simplicidad y capacidad de realizar anotaciones manuales de forma independiente para imágenes. Se trata de una extensión HTML que permite cargar las imágenes térmicas y posteriormente insertarle atributos, permitiendo crear regiones interactivas en las imágenes térmicas, que responden a la interacción del usuario, como hacer clic o pasar el ratón por encima de ellas. Los pasos en concreto fueron los siguientes:

- **Carga de imágenes**: Como se puede observar en la Figura 3-10, aparece una pestaña desplegable con el nombre de "Project", y dentro de esta, la opción de subir nuevas imágenes, donde directamente al pulsar sobre esta ofrece al usuario la posibilidad de subir imágenes desde la carpeta de archivos deseada. Esta imagen puede ser cualquier formato compatible con el HTML, como JPEG, PNG, o GIF.

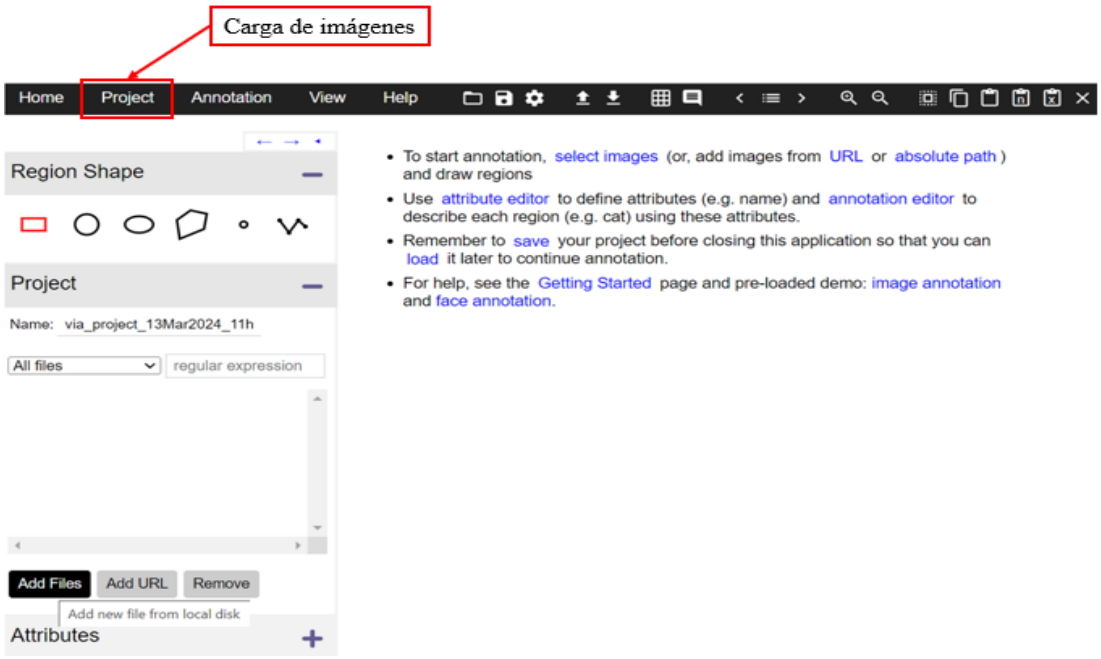


Figura 3-10 Página principal al abrir el software VGG Image Annotator, indicando opción carga de imágenes (Elaboración propia)

- **Creación de atributos:** Tras abrir una imagen térmica, para poder aprender posteriormente la red neuronal, es necesario insertar ciertos atributos a las regiones trazadas para una correcta clasificación de los diferentes defectos. Como se puede observar en la Figura 3-11, se han creado 4 diferentes tipos de atributos, específicamente humedades, grietas, puentes térmicos y filtraciones de aire, que son con las cuales se ha trabajado.
- **Identificación de las patologías:** Tras la creación de los atributos, el HTML ofrece la opción de dibujar/trazar el contorno de las diferentes patologías, definiendo y seccionando la imagen en áreas específicas de interés, conocidas como "regiones" a través de la opción *Region Shape* → *polygon región shape*. Cada contorno se define mediante coordenadas cartesianas (es decir, coordenadas x e y) (véase Figura 3-11).
- **Clasificación de las patologías:** Una vez definidas los contornos de las patologías, pinchando encima de estos polígonos creados por el usuario con el ratón aparece una lista desplegable donde se puede elegir el tipo de patología existente, listado que proviene de la creación de atributos hecha previamente (véase Figura 3-11).
- **Almacenamiento:** Por último, se guarda el trabajo de edición en un archivo "json", en la pestaña "Annotation", el cual contiene el código que define todas las zonas trazadas con sus correspondientes coordenadas en cada imagen cargada, junto al tipo de patología asignada, para que así pueda ser leído por la red neuronal, tal y como se puede apreciar en la Figura 3-12.

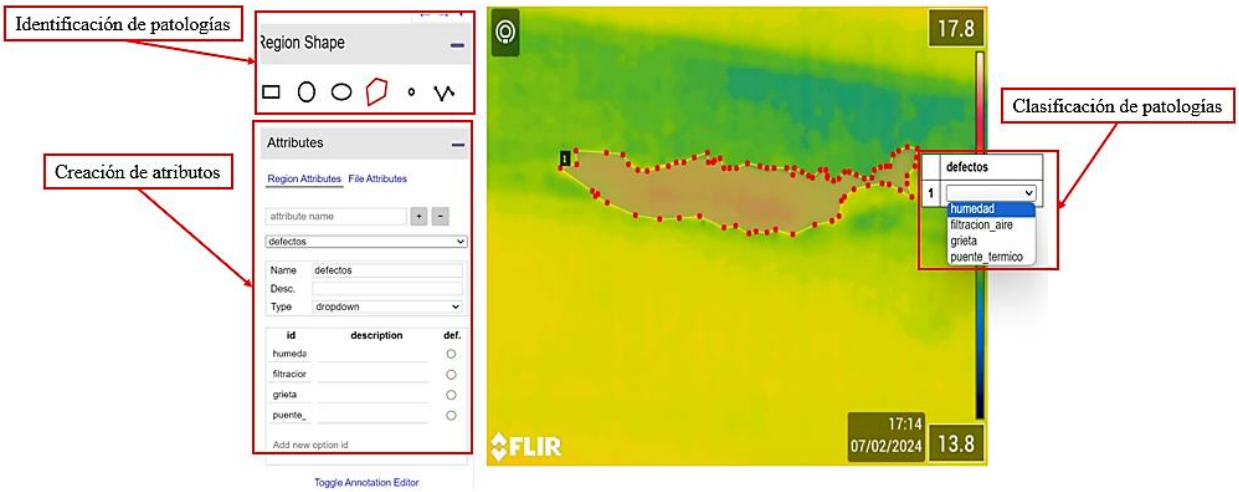


Figura 3-11 Identificación de una patología mediante la creación de un polígono y asignación de su tipología (Elaboración propia)

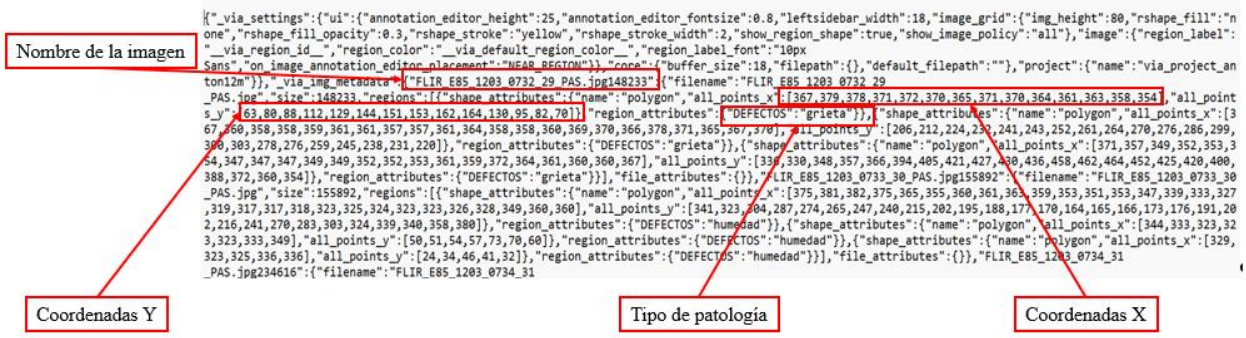
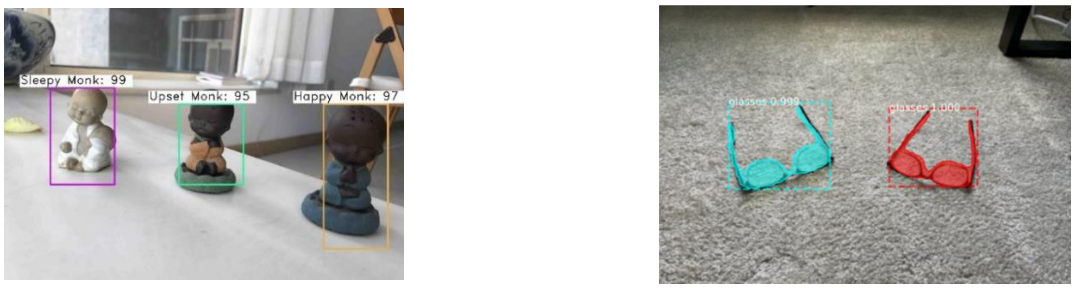


Figura 3-12 Código resultante JSON tras la identificación de los defectos (Elaboración propia)

3.5 Modelo de *Deep Learning* utilizado

El modelo de *deep learning* utilizado para este trabajo ha sido el Mask R-CNN, que significa Mask *Region-based Convolutional Neural Network*, desarrollado por Facebook AI Research. Es una extensión del modelo Faster R-CNN, que se utiliza para la detección y clasificación de objetos y regiones de interés, en inglés *regions of interest* (ROIs), mediante cuadros delimitadores o más bien conocidos como *bounding boxes*, asignado a cada uno la clase/clasificación correspondiente [57]. Mask R-CNN extiende la funcionalidad de Faster R-CNN al incluir la capacidad de generar máscaras precisas para cada objeto detectado dentro de los *bounding boxes*, lo que permite segmentarlos de manera más precisa en la imagen, ya que los objetos dentro de los cuadros delimitadores casi nunca serán rectángulos, sino una forma de contorno generalmente irregular (véase Figura 3-13).



a) **b)**

Figura 3-13 Comparación Faster R-CNN (a)) y Mask R-CNN (b)) mediante ejemplos de resultados de dichos modelos (Extraídos de [58], [59])

El funcionamiento de Mask R-CNN se puede dividir en varias etapas, en donde el esquema se muestra en la Figura 3-14:

- ***Input & Backbone network* (Red de base):** La imagen de entrada pasa a través de una red neuronal convolucional, convolucional ya que el peso de las neuronas es una matriz de variables de números (*kernels*) en vez de ser solamente una variable, siendo este tipo de redes los más adecuados para imágenes según la literatura. En este caso, la arquitectura CNN (*Convolutional Neural Network*) utilizada en este trabajo es la Red Residual de 50 capas convolucionales ocultas (ResNet50), es decir, 50 capas entre la capa de entrada y la capa de salida. ResNet50 se trata de la opción más habitual en los casos de extracción de características de imágenes, detectando regiones de interés (ROIs) que pueden contener objetos [60]. Estos ROIs luego pasan por una red piramidal de características (*Feature Pyramid Network* (FPN)). Esta red trabaja de arriba abajo con conexiones laterales para construir una pirámide de características, siendo el tamaño de las capas ocultas utilizadas de 256. Las razones para utilizar una red conjunta ResNet50-FPN para la extracción de características (mapa de características o *feature map*) sobre la imagen de entrada son las excelentes ganancias tanto en precisión como en velocidad. En este caso, la imagen de entrada es una de las imágenes térmicas adquiridas, teniendo esa entrada el formato tensor necesario para el correcto funcionamiento de la ResNet50-FPN, al ser imágenes RGB teniendo así 3 canales: alto de la imagen (en píxeles) x ancho de la imagen (en píxeles) x 3.
- ***Region Proporsal Network* (RPN) (Red de propuesta de región):** Esta red se encarga de general propuestas de regiones que podrían contener objetos tras introducir como entrada las *feature maps* de la *backbone network*. Estas propuestas se basan en cajas de anclajes, *anchor boxes*, que se escalan y se desplazan sobre la salida de la red de base. Dichas propuestas de regiones son cajas delimitadoras con una clase de objeto asignada a cada caja, conocido como *object bounding boxes* y *object scores*, respectivamente.
- ***ROI Align*:** Este proceso matemático sirve para el alineamiento píxel a píxel de los *object bounding boxes* y *object scores* con los *features maps*, preservando la ubicación espacial exacta de cada objecto, específicamente en este caso, los defectos constructivos. Tras ese alineamiento, la salida del *ROI Align* se conoce como *candidate object bounding box*. La RPN pierde en parte la información espacial de las *feature maps* debido a su arquitectura, de ahí de aplicar esta solución.
- ***Branches for classification, bounding box, and mask prediction* (Ramas para clasificación, predicción de cuadros delimitadores y predicción de máscaras):** A partir de los *object bounding boxes*, Mask R-CNN realiza tres tareas principales:
  - Clasificación: Refina la predicción de la clase del objeto presente en el cuadro delimitador final, con respecto al dado en el RPN (*final object class*).
  - Cuadros delimitadores finales: Refina las coordenadas del cuadro delimitador con respecto al dado en el RPN (*final object bounding box*), teniendo que emplear de nuevo el *ROI Align* para colocar correctamente cada *final object bounding box* en los *feature maps*.
  - Predicción de máscaras: Genera una máscara binaria precisa para indicar con precisión la región exacta del objeto dentro del cuadro delimitador final (*final object mask*).
- **Output (Salida):** Salen en la capa de salida los *final object class*es, *final object bounding boxes* y *final object masks*. En el caso de este trabajo, los cuadros delimitadores, las etiquetas de clase y las máscaras segmentadas serán referidas a los defectos existentes en cada imagen si el modelo ha aprendido correctamente, colocándolas encima de dichas imágenes térmicas.

En resumen, Mask R-CNN combina la clasificación (*class*), la detección (*bounding box*) y segmentación (*mask*) de instancias (objetos) en una sola arquitectura, permitiendo así localizar y clasificar patologías en una imagen, y segmentarlas de manera precisa mediante máscaras binarias y convirtiéndolo en una herramienta útil para aplicaciones de reconocimiento de defectos constructivos.

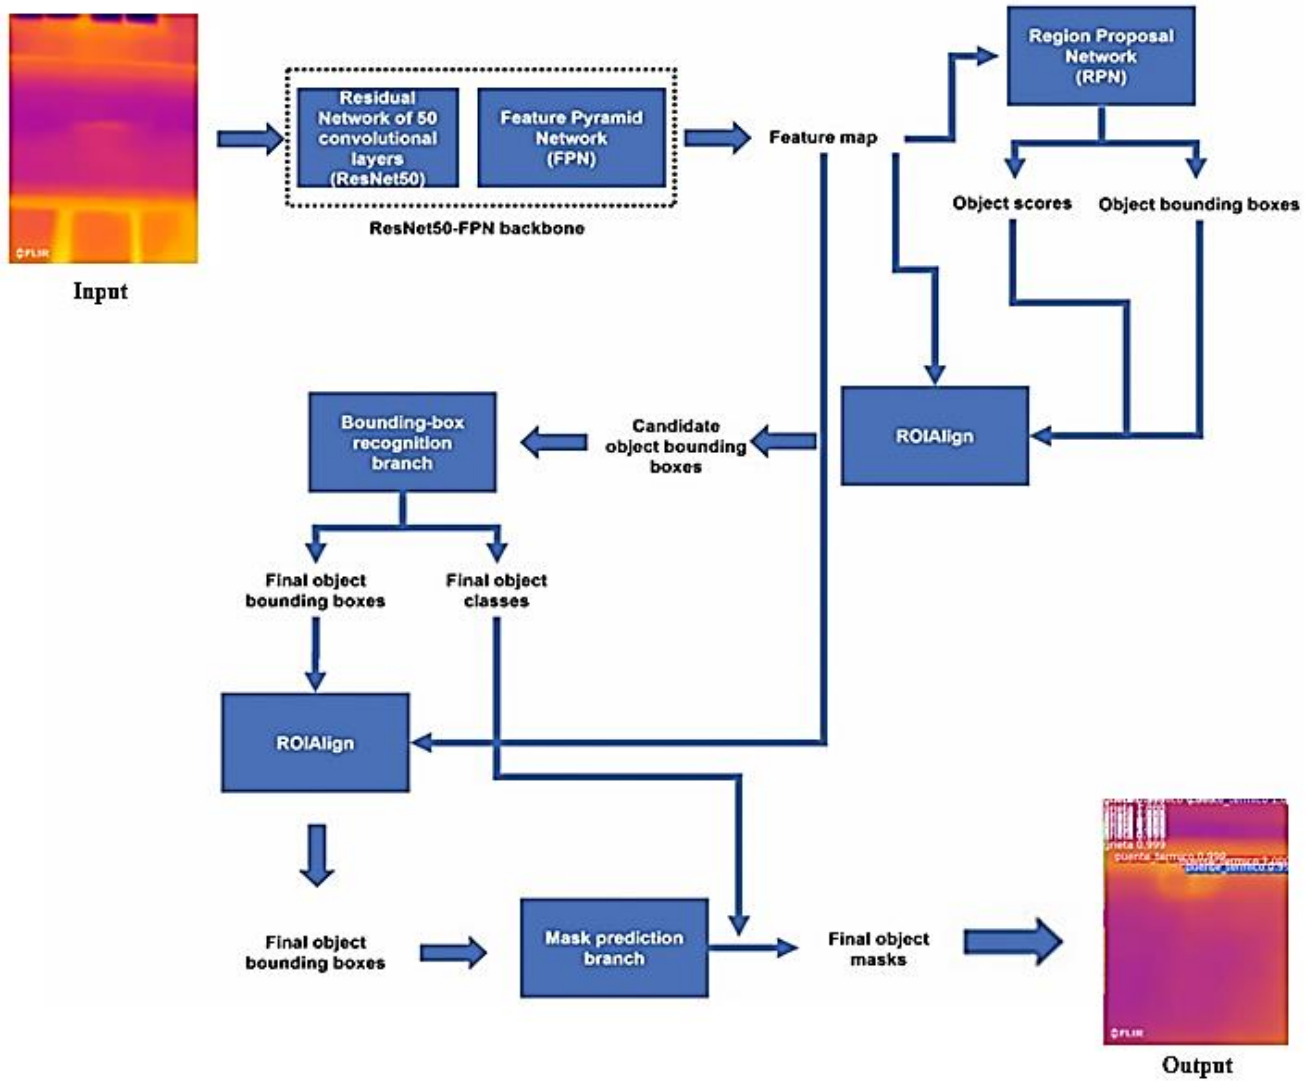


Figura 3-14 Esquema del funcionamiento de Mask R-CNN (Elaboración propia)

3.6 Preparación del aprendizaje del modelo de *Deep Learning*

Para el proceso de aprendizaje del Mask R-CNN, se sigue el aprendizaje supervisado, siendo esta red neuronal de tipo backforward. Por tanto, en cada iteracción (epoch) del aprendizaje, el modelo DL parte de las imágenes de entrada, y actualiza sus pesos (*kernels*) a través de sus capas ocultas hasta obtener unas salidas. Esas imágenes de entrada utilizadas se denominan banco de imágenes de entrenamiento (*training dataset*), en donde las salidas se comparan con los etiquetados realizados en dichas imágenes mediante el software VGG Image Annotator ya descrito. Se obtendrá una desviación respecto a la realidad tras cada imagen, tanto en la *final object class*, como en el *final object bounding box* y en el *final object mask*, desviación numérica que sumando las desviaciones de las 3 salidas da lo que se conoce como pérdida en el entrenamiento, *training loss*. Ese *training loss* se trata de corregir modificando los *kernels* del modelo DL en un salto de cambio dado por una cifra numérica conocido como ratio de aprendizaje, *learning rate*, que en Mask R-CNN es menor de 0,2 pero siempre mayor que 0. Con esa actualización de los *kernels*, se calcularía de nuevo el *training loss* en la siguiente imagen del *training dataset*. Al terminar con todas las imágenes del *training dataset*, para cerrar el primer *epoch*, en otro banco de imágenes conocido como banco de imágenes de validación, *validation dataset*, se aplica el modelo aprendido hasta ese momento, pero sin actualizar los kernels en este nuevo banco, obteniendo una ponderación de la pérdida en la validación, teniendo en cuenta las 3 desviaciones existentes, *validation loss*. Esta *validation loss* se trata también de reducir lo máximo posible, donde tras obtener

dicho parámetro, los *kernels* son de nuevo actualizados para usarlos en el siguiente *epoch*, que se arrancaría de nuevo con el *training dataset*, y así sucesivamente hasta el último *epoch*. Un buen aprendizaje tiene los *training loss* y *validation loss* lo más próximo posible al cero, pudiendo considerar aceptable siempre y cuando se está por igual o por debajo del 1. Asimismo, es fundamental que ambos *losses* converjan con el paso de los *epochs*.

Una de las técnicas más populares para ayudar a un buen aprendizaje de un modelo DL es el que precisamente se va a llevar a cabo en este trabajo. Esta técnica es conocida como *cross validation*, que permite evaluar un modelo DL con datos limitados de entrada, como se trata del presente proyecto. En un primer lugar, se separa las series de datos juntados previamente, el *training dataset* junto al *validation dataset*, de manera aleatoria en "k" carpetas o *folds*, en inglés, diferentes. Así, en cada carpeta se tendrá un *training dataset* y un validation dataset en concreto, pasando en la siguiente carpeta la *validation dataset* al *training dataset*, y parte del *training dataset* al *validation dataset*, y así sucesivamente. Nótese que el *training dataset* suele representar el 70-80 % del total juntando con el *validation dataset*, siendo así siempre un banco de imágenes mayor. Por tanto, en cada *fold* se puede aplicar un número de *epochs* determinado e incluso un *learning rate* diferente. Según la literatura, el número de "k" carpetas recomendado es entre 5 y 10.

Por otro lado, la transferencia de aprendizaje, *transfer learning*, se basa en explotar conocimientos aprendidos (*kernels*) de un modelo DL en un banco de imágenes determinado a un nuevo banco de imágenes, para resolver otro problema específico [61]. Gracias a este enfoque, se reducen los recursos utilizados y la cantidad de datos etiquetados necesarios para entrenar modelos DL en otras situaciones, ya que no se parte con *kernels* totalmente desconocidos, haciendo que el *transfer learning* sea una técnica bastante popular. En este contexto, los *kernels* utilizados en este trabajo como partida vienen tras aprender el modelo Mask R-CNN a partir del conjunto de datos de Microsoft COCO. Este conjunto de datos proporciona una amplia variedad de imágenes del mundo real, en este caso visibles, anotadas con información detallada sobre los objetos presentes en ellas, así como su contexto. De este modo, los *kernels* de partida se tienen que adaptar de imágenes visibles a térmicas, de ahí el motivo de tener que actualizar los *kernels* de todas las capas del modelo, ya que pudiese dar el caso de solamente ser necesario actualizar parte de la red, tal y como se realiza en la literatura.

Además, se ha utilizado en el aprendizaje el método g*radient descent*, que se trata de una técnica conocida en *deep learning* que ajusta los *kernels* del modelo para minimizar una función de pérdida (*loss training* y *loss validation*). Este método busca identificar los *kernels* del modelo que reducen el error en los datos de aprendizaje, utilizando el gradiente para medir cómo cambia la función de pérdida al modificar los *kernels*, basándose el gradiente en el valor dado en el *learning rate*. Entre sus variantes, el *batch gradient descent* ha sido el empleado en este trabajo. Esta técnica calcula el *loss training* para cada imagen del *training dataset*, actualizando el modelo con cada imagen del *training dataset* y no por salto de intervalos de imágenes. Esta técnica es empleada generalmente en casos donde el usuario no posee de un gran banco de datos, como es el caso del presente proyecto, ya que, debido a las limitaciones de espacio sometido a estudio, el rango de imágenes se reduce considerablemente [62].

Una vez conocidos y aplicados estos conceptos al modelo DL seleccionado, se puede comenzar a exponer los bancos de imágenes utilizados. Dado la baja calidad de las imágenes térmicas adquiridas con la cámara *low cost* (FLIR ONE EDGE), estas se han decidido considerarlas como un banco de imágenes de testeo, *testing dataset*. En otras palabras, los *training dataset* y *validation dataset* será utilizando las imágenes térmicas obtenidas con la cámara FLIR E85, asegurando así un mejor aprendizaje del modelo. Luego, con el modelo aprendido, la finalidad es cuantificar su prestación en la localización, delimitación y clasificación de defectos constructivos en imágenes térmicas de peor calidad en resolución térmica, que es lo más habitual en el ámbito profesional y lo más prometedor e interesante de este trabajo. Si se consigue que el modelo aprendido con una cámara de alta gama luego sirva para ser usado en cualquier momento en otros tipos de imágenes obtenidas por cámaras de bajo coste, el hito conseguido en este trabajo sería un gran éxito en el campo de la investigación y profesional.

En este caso, para el aprendizaje se ha utilizado 50 imágenes térmicas, donde dentro de estas 50 imágenes, para el entrenamiento fueron utilizadas 40 (*training dataset*), mientras que 10 fueron utilizadas de validación (*validation dataset*), con un k *fold* igual a 5, 120 *epochs* en cada fold y siempre con un *learning rate* igual a 0,001 para que el gradiente no sea muy brusco. El *testing dataset* se puede ver con detalle en uno de los apartados del apartado 4. En cada imagen de aprendizaje se tiene de 1 hasta 4 regiones de interés (ROIs), pudiendo ser humedades, grietas, puentes térmicos y/o filtraciones de aire. De las ROIs introducidas al modelo, el 50 % fueron humedades, el 20 % puentes térmicos, el 17 % filtraciones de aire y un 13 % grietas. A continuación, en la Tabla 3-3 se muestran 2 imágenes utilizadas para aprender al modelo, junto a sus imágenes visibles y térmicas, para poder hacer una mejor comparación. En estas, se pueden apreciar los 4 tipos de defectos que se quieren encontrar, y la manera de identificarlos antes de ingresar la imagen al modelo DL.

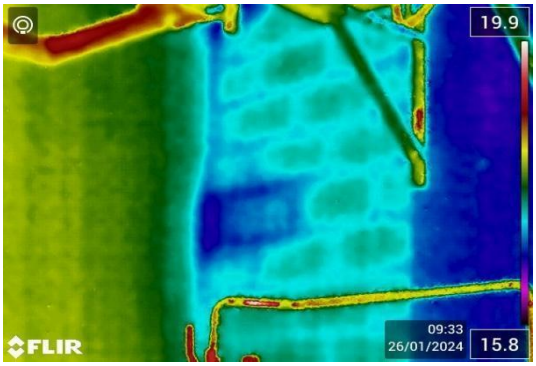
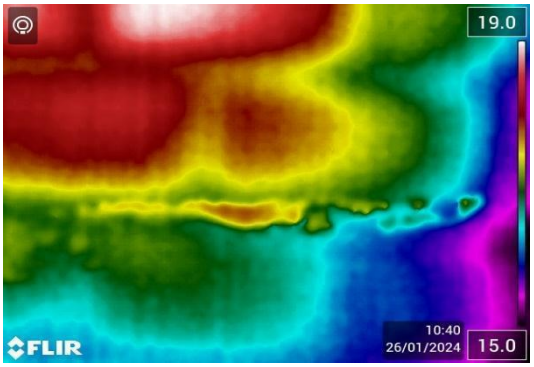
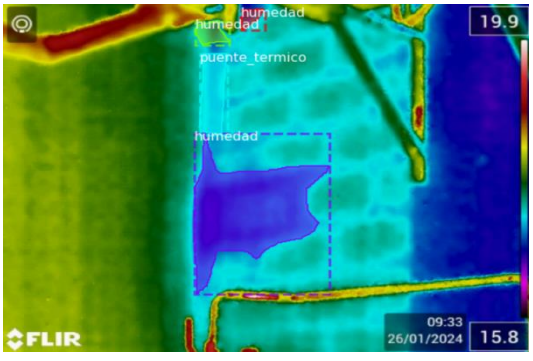
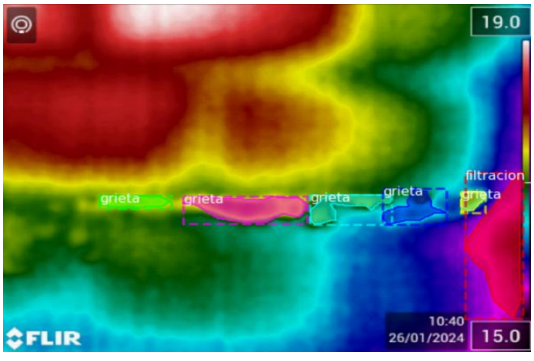
Imagen	**1**	**2**
Imagen visible		
Imagen térmica		
Imagen utilizada en el modelo		

Tabla 3-3 Comparativa desde la imagen visible y térmica con la imagen que entra al modelo (Elaboración propia)

Por último, se establecieron diferentes hiper parámetros, que son variables de ajustes que permiten administrar el modelo, fundamentales para ajustar y optimizar el rendimiento de este durante el aprendizaje, y que fueron: *Training Batch size*, *Validation Batch size*, *Epochs* y *Learning rate*.

- ***Training batch size*:** Se trata del número de imágenes del *training dataset* que se utilizarán en cada iteración durante el proceso de aprendizaje. Su valor en este caso es el tamaño del *training dataset*, ya que se ha considerado seguir el método *batch gradient descent*.
- ***Validation batch size*:** Similar al *training batch size*, pero aplicado al conjunto de validación. Su valor es el tamaño del *validation dataset*, ya que se ha considerado seguir el método *batch gradient descent*.
- ***Epochs*:** Iteraciones en el aprendizaje, tal y como se ha explicado previamente. Establecido su número en 600, implica que, durante el proceso de aprendizaje, el modelo pasará por todo el conjunto de datos 600 veces. Con 120 *epochs* por cada *fold*, se buscó lograr una convergencia más completa del modelo (l*oss training* y *loss validation*) para así hacer una mejor captura de los patrones presentes en los datos.
- ***Learning rate*:** Controla qué tan rápido se actualizan los pesos del modelo durante el aprendizaje, tal y como se ha explicado previamente. Es un factor de escala aplicado a los gradientes calculados durante la retropropagación, cuyo valor es 0,001, mejorando la estabilidad del entrenamiento.

La implementación del Mask R-CNN se realizó en el lenguaje de programación de Python, versión 3.10, utilizando TensorFlow 2.13 y Keras 2.13 como librerías principales. Específicamente, el ordenador utilizado para el aprendizaje fue un ZenBook Pro Duo UX582ZM_UX582ZM con un procesador 12th Gen Intel® Core™ i7-12700 H.

Con el fin de ofrecer una comprensión más detallada del trabajo realizado, se han establecido dos escenarios distintos. El primero (Escenario 1), el modelo durante el aprendizaje se enfoca en distinguir entre lo que se considera defecto y lo que no, mientras que el segundo (Escenario 2), el modelo durante el aprendizaje se centra en distinguir entre no defecto y defecto, y a mayores clasificar los diferentes tipos de defectos detectados, que incluyen humedad, grietas, puentes térmicos y filtración de aire. Esta división permite abordar de manera específica y detallada cada aspecto relacionado con la detección y clasificación de defectos en el contexto del proyecto de investigación.

3.7 Descripción del código para ejecutar el modelo de *Deep Learning*

El procedimiento para ejecutar el modelo Mask R-CNN se llevó a cabo mediante la adaptación del código proporcionado en la referencia [63]. Dicho código, está disponible en la plataforma de desarrollo colaborativo GitHub, reconocida como una de las principales plataformas para la creación de proyectos de código abierto. Esta plataforma se distingue por sus capacidades colaborativas, que facilitan la contribución de conocimientos por parte de diversos usuarios para mejorar el código existente.

En el contexto de este trabajo, se emplearon todos los archivos de código disponibles, con una adaptación específica del archivo "custom.py" para adecuarlo al contexto de esta investigación. La extensión ".py" indica que el código está escrito en el lenguaje de programación Python, tal como se mencionó en el apartado anterior. Se destaca que Python es un lenguaje de código abierto reconocido por su facilidad de escritura y su bajo consumo de recursos, lo que lo hace idóneo para el funcionamiento de sus potentes librerías, incluida la ejecución del modelo Mask R-CNN. (Figura 3-15, Figura 3-16, Figura 3-17).

En la clase denominada "CustomConfig", se optó por utilizar como red de base (*backbone*) ResNet50, tal y como se ha explicado en secciones anteriores ya que, por defecto, el modelo emplea la arquitectura ResNet101, que cuenta con 101 capas ocultas en contraste con las 50 capas de ResNet50. Dado el contexto de este estudio, caracterizado por la limitada cantidad de datos de entrada, se decidió seleccionar la ResNet50 para agilizar el proceso de aprendizaje del modelo, dada la poca cantidad de datos de entrada. Además, por defecto, las imágenes de entrada se redimensionaron a 1024 píxeles tanto de ancho como de alto, por lo que, dada la baja resolución de las cámaras térmicas, se ha considerado reducir a 512 (ver “IMAGE_MIN_DIM” y “IMAGE_MAX_DIM), además de utilizar la CPU del ordenador en lugar de la GPU (ver “GPU_COUNT”), teniendo que igualar la variable

"IMAGES_PER_GPU" a 1. En cuanto al parámetro "NUM_CLASSES", cuando se trata del Escenario 1, es decir, diferenciar entre región sana y defecto, hay que igualarlo a 2, mientras que, si se trata del Escenario 2, que consiste en la diferenciación de los 4 tipos de defectos objeto de estudio, este valor ha de ser igual a 5. Al aplicar el método *batch gradient descent*, "STEPS_PER_EPOCH" y "VALIDATION_STEPS" tienen que igualarse a la cantidad de imágenes de entrada del conjunto de entrenamiento y de validación, respectivamente.

```
class CustomConfig(Config):
    BACKBONE = "resnet50"
    IMAGE_MIN_DIM = 512
    IMAGE_MAX_DIM = 512
    GPU_COUNT = 1
    IMAGES_PER_GPU = 1
    NUM_CLASSES = 1 + 4
    STEPS_PER_EPOCH = 40
    VALIDATION_STEPS = 10
```

Figura 3-15 Modificaciones realizadas en la clase "CustomConfig" (Elaboración propia)

Dentro de la clase "CustomDataset", en la función "load_custom", se lleva a cabo la definición de cada tipo de defecto constructivo. Para lograr esto, se asigna el valor igual a 1 si el objetivo es distinguir únicamente entre defecto y no defecto. Sin embargo, si se busca diferenciar entre diferentes tipologías de defectos, se asignan valores diferentes para cada una de ellas. Además, en esta misma función se implementa la técnica del cross validation. En este sentido, se establece que "N_Folds" sea igual a 5, lo cual implica que el conjunto global, considerando tanto el conjunto de entrenamiento como el de validación, se divide en 5 particiones diferentes, es decir, 5 carpetas distintas.

```
class CustomDataset(utils.Dataset):

    def load_custom(self, dataset_dir, subset, Fold):
        self.add_class("object", 1, "grieta")
        self.add_class("object", 2, "filtracion_aire")
        self.add_class("object", 3, "puente_termico")
        self.add_class("object", 4, "humedad")
```

```
for a in annotations:
    polygons = [r['shape_attributes'] for r in a['regions']]
    objects = [s['region_attributes']['defectos'] for s in a['regions']]
    print("objects:",objects)
    name_dict = {"grieta": 1,"filtracion_aire": 2,"puente_termico": 3,"humedad": 4}
```

a)

```
assert subset in ["train", "val"]
dataset_dir = os.path.join(dataset_dir, "train")
N_Folds = 5
```

```
k_fold = KFold(n_splits = N_Folds, shuffle = True)

for i, (train, val) in enumerate(k_fold.split(annotations1)):

    if subset == "train" and Fold == i:
        for index in train:
            annotations.append(annotations1[index])

    elif subset == "val" and Fold == i:
        for index in val:
            annotations.append(annotations1[index])
```

b)

Figura 3-16 Modificaciones realizadas en la clase "CustomDataset", a) definiendo los tipos de defectos, y b) el cross validation (Elaboración propia)

Por último, en la función "train" se define las iteraciones para el aprendizaje, *epochs*, en cada carpeta, en este caso 120 para todas, indicando que se va a aprender todas las capas del modelo por la justificación dada en el apartado previo.

```
def train(model):
    epoch_count = 0
    for i in range(5):
        dataset_train = CustomDataset()
        dataset_train.load_custom(os.path.join(ROOT_DIR, "dataset"), "train", i)
        dataset_train.prepare()
        dataset_val = CustomDataset()
        dataset_val.load_custom(os.path.join(ROOT_DIR, "dataset"), "val", i)
        dataset_val.prepare()
        epoch_count += 120
        model.train(dataset_train, dataset_val,
                    learning_rate=config.LEARNING_RATE,
                    epochs=epoch_count,
                    layers='all')
```

Figura 3-17 Modificaciones realizadas en la función "train" (Elaboración propia)

4 RESULTADOS Y DISCUSIÓN

Este apartado de resultados y discusión se centrará primero en el análisis del aprendizaje alcanzado tanto en el Escenario 1 como en el Escenario 2 descritos en el apartado 3.7, mostrándose visualmente los resultados en las diferentes gráficas para facilitar su comparación. Además, se analizará la prestación del modelo de deep learning tras el aprendizaje aplicado a las imágenes térmicas de la cámara low cost, discutiendo e interpretando los resultados obtenidos en ambos escenarios.

4.1 Resultado del aprendizaje

El objetivo durante la etapa de aprendizaje de un modelo DL es minimizar esta pérdida para poder acercarse más a los resultados reales. Tal y como se ha descrito en el apartado 3.7, en el modelo de Mask R-CNN se tiene el *loss training* y el *loss validation*.

4.1.1 Resultado del aprendizaje en el Escenario 1

A continuación, se muestra el resultado del aprendizaje del Escenario 1, es decir, identificar qué píxeles de cada imagen del *training dataset* y del *validation dataset* son no defectos y defectos, con el etiquetado realizado previamente. Se muestran las gráficas del *loss training* y del *loss validation* según los *epochs*, en la Figura 4-1 y la Figura 4-2, respectivamente, donde se puede apreciar la estabilidad de las curvas en la parte final del proceso. Además, se agrega una línea de tendencia a cada evolución para una mejor visualización.

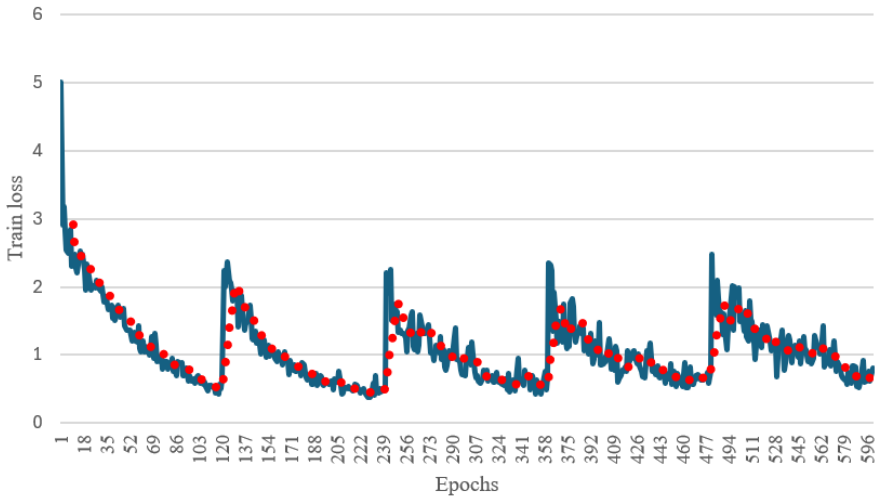


Figura 4-1 Gráfica del *loss training* del Escenario 1, marcando su línea de tendencia con puntos rojos (Elaboración propia)

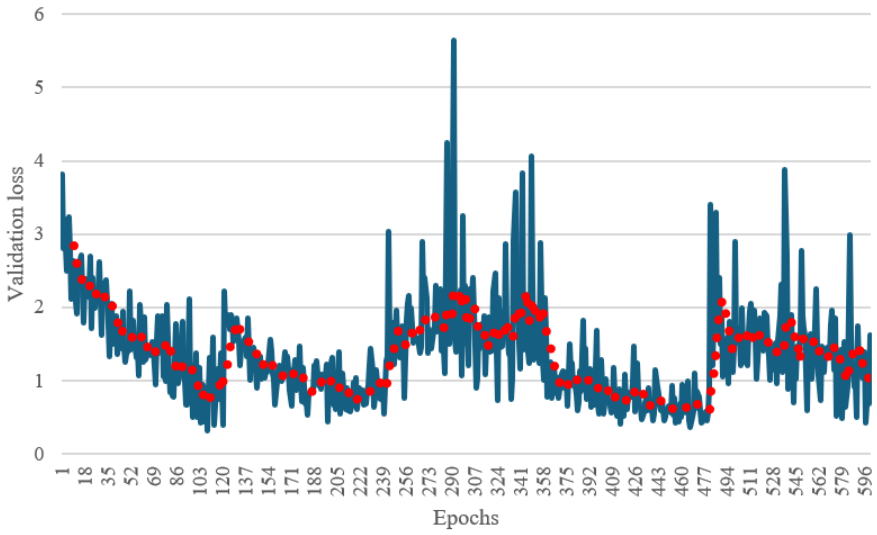


Figura 4-2 Gráfica del *loss validation* del Escenario 1, marcando su línea de tendencia con puntos rojos (Elaboración propia)

Además, se elaboró una gráfica en donde se combinan ambas, para poder observar las diferencias entre ambos procesos, tal y como se puede apreciar en la Figura 4-3. Para poder mostrar de una manera más visual los resultados, estas curvas están ayudadas de las líneas de tendencia, que se calculan como las líneas que más se ajustan a la evolución real.

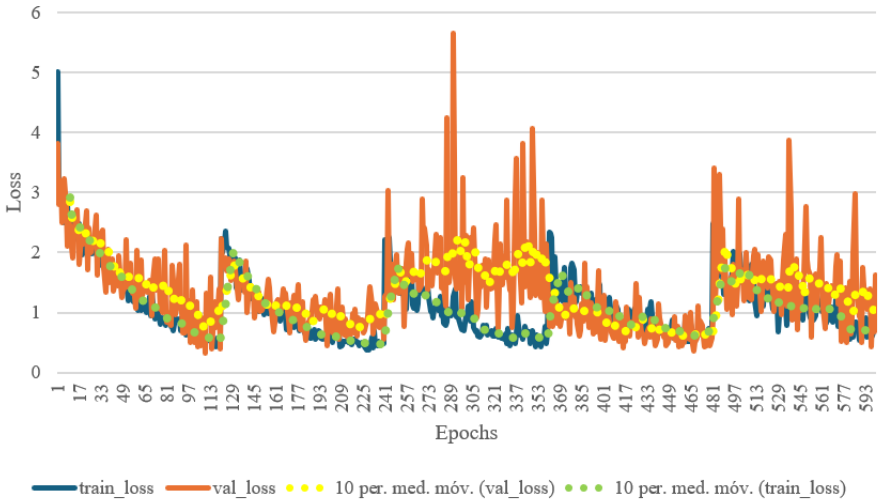


Figura 4-3 Gráfica comparativa de entrenamiento y validación en el Escenario 1 (Elaboración propia)

Se observa que las curvas correspondientes del loss training y del loss validation convergen hacia la parte final del proceso de aprendizaje, en torno al epoch 360. Esta convergencia es más fácil de visualizar a partir de las líneas de tendencia que de las evoluciones reales. Además, las evoluciones de los valores de pérdida de entrenamiento y validación se estabilizan después del punto de convergencia, estabilizándose el loss training en torno a 0,7 y el loss validation en torno a 1. Los picos que hay cada 120 epochs es debido a que se cambia de k-fold, tal y como se explicó en el apartado 3.7. Por otra parte, la diferencia entre el loss training y el loss validation se puede estimar al término del aprendizaje de 0,3, siendo aceptable las pérdidas de ambas, aunque no óptimas debido al pequeño banco de imágenes de entrada.

4.1.2 Resultado del aprendizaje en el Escenario 2

En el caso del Escenario 2, donde se identifica en cada pixel del *training dataset* y del *validation dataset* si es un no defecto, y en caso de ser un defecto, de qué tipo es, tras el etiquetado previo. En un primer lugar, y al igual que en el Escenario 1, se muestra primero la Figura 4-4, que corresponde a la gráfica del *loss training* en función del *epoch*, la cual, muestra bastantes similitudes con el *loss training* del Escenario 1 (Figura 4-1), pudiéndose apreciar los pequeños saltos en cada cambio de *fold*, y ligera tendencia hacia valores cercanos al 1.

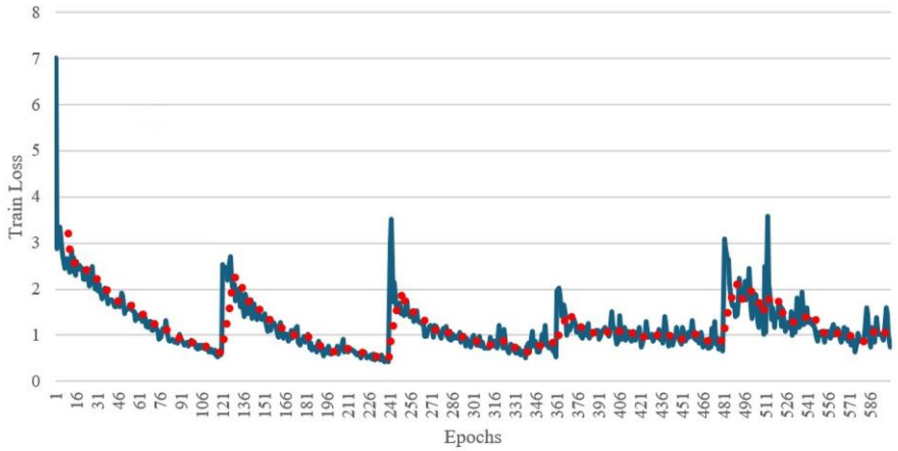


Figura 4-4 Gráfica del *loss training* del Escenario 2, marcando su línea de tendencia con puntos rojos (Elaboración propia)

En la Figura 4-5 se presenta el aprendizaje del modelo durante el proceso de validación. La gráfica del *loss validation* también muestra ciertas similitudes al *loss validation* del Escenario 1 (Figura 4-2), pudiéndose apreciar de nuevo los pequeños saltos en cada cambio de *fold*, y ligera tendencia hacia valores cercanos al 1.

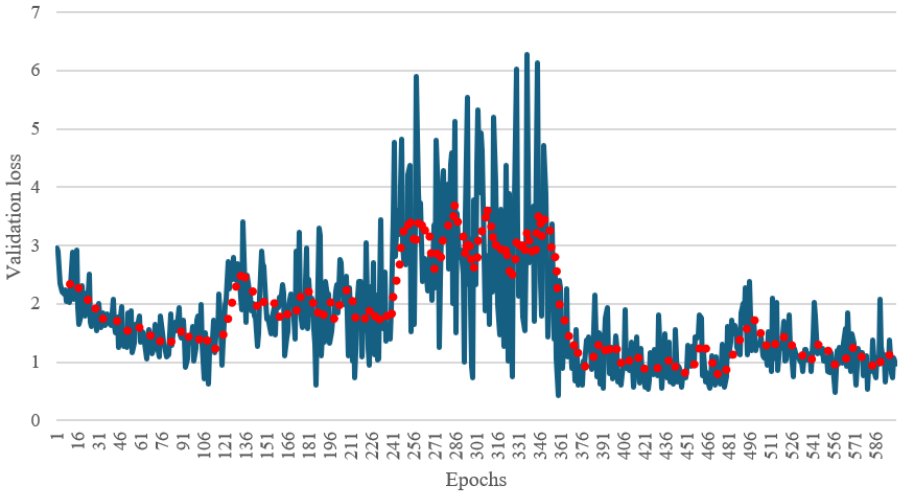


Figura 4-5 Gráfica del *loss validation* del Escenario 2, marcando su línea de tendencia con puntos rojos (Elaboración propia)

En la Figura 4-6 se presenta una comparación directa entre las curvas de pérdida durante el entrenamiento y la validación. Esta representación gráfica proporciona una visión más clara de la

relación entre la pérdida en el conjunto de entrenamiento y en el conjunto de validación a lo largo del tiempo.

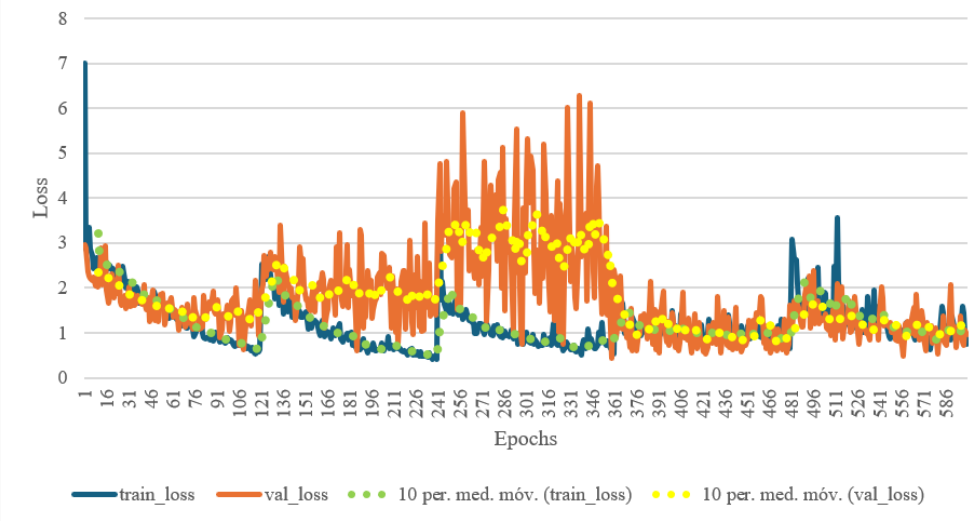


Figura 4-6 Gráfica comparativa de entrenamiento y validación en el Escenario 2 (Elaboración propia)

En esta última gráfica, se puede observar cómo las pérdidas de entrenamiento y validación se mantienen bastante similares durante la mayor parte del proceso de entrenamiento, lo cual sugiere que el modelo está aprendiendo de manera consistente tanto de los datos de entrenamiento como de los datos de validación. Sin embargo, el repentino aumento en las pérdidas de validación alrededor del *epoch* 240 indica que el modelo esté comenzando a sobreajustarse (en esa *epoch* hay cambio de *fold*), lo que resulta en una prestación deficiente. Sin embargo, después del *epoch* 360, las pérdidas de validación se estabilizan, lo que sugiere que el modelo logra generalizar mejor después de ese punto y se mantiene estable en su rendimiento teniendo en cuenta también el *loss training*. Como se ha comentado, el *loss training* tiene tendencia al valor 1, incluso tras estabilizarse, y el *loss validation* en torno a 1, también incluso tras estabilizarse. Así que apenas hay diferencias entre ambas.

Comparando con el Escenario 1, el *loss validation* se mantiene en un valor común en ambos tras estabilizarse (1), y el *loss training* pasa de 0,7 a 1 en este Escenario 2. En los dos escenarios el *epoch* de convergencia coincide, 360. Los valores de pérdidas del Escenario 2 siguen siendo aceptables a pesar de que se empeora en el *loss training* comparando con el Escenario 1, un hecho razonable ya que el aprendizaje del Escenario 2 es más complejo, tratando de clasificar el defecto identificado según su tipología como valor añadido.

4.2 Prestación del modelo aprendido aplicado a imágenes de cámaras térmicas *low cost*

Este apartado se centra en evaluar la capacidad de generalización del modelo aprendido, aprendido con imágenes de cámaras de alta gama (FLIR E85), al aplicarlo a imágenes térmicas capturadas por cámaras térmicas *low cost*, específicamente la FLIR ONE EDGE. Es importante recordar que el modelo fue aprendido con una amplia variedad de defectos, garantizando así una cierta igualdad en la representación de los distintos tipos de anomalías presentes en las imágenes utilizadas para el aprendizaje (ver Apartado 3.7).

Cuando se evalúa la prestación de un modelo DL que trabaje con imágenes y a la segmentación de objetos (máscaras), se está refiriendo a los parámetros de precisión y exactitud (*recall*) como métricas claves para medir y cuantificar la eficacia de un trabajo. La precisión se centra en la proporción de predicciones correctas realizadas por el modelo DL entre todas sus predicciones. Mientras que el *recall* se enfoca en la proporción de casos positivos que el modelo ha identificado correctamente entre todos

los casos positivos reales. Ambas métricas son fundamentales para comprender el rendimiento y la eficacia de un modelo en diferentes escenarios. Para comprender mejor ambos conceptos, se presenta la Figura 4-7, donde se puede observar una diana y la diferencia entre precisión y exactitud, y sus correspondientes ecuaciones (Ecuaciones (10) y (11)).

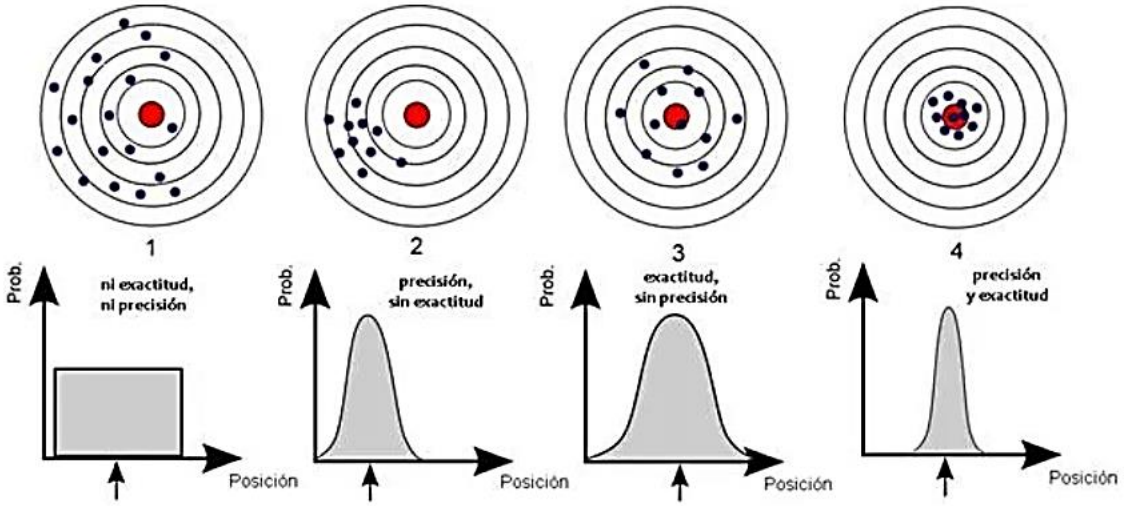


Figura 4-7 Diferencia entre precisión y exactitud (Extraído de [64])

$$\text{Precisión} = TP/(TP + FP) \tag{10}$$

$$\textit{Recall} = TP/(TP + FN) \tag{11}$$

donde TP son los píxeles predichos de forma correcta (*True Positives*), FP son los píxeles predichos de forma errónea (*False Positives*) y FN los píxeles no predichos pero que se tendría que predecir (*False Negatives*). Estas ecuaciones están representadas en tanto por uno, destacando que muchas veces se representan en porcentajes para una mejor visualización. La combinación de ambas métricas, dándole la misma ponderación a cada una de ellas, es lo que se conoce como *F-score* (Ecuación (12)):

$$\textit{F-score} = (2 \cdot \text{Precisión} \cdot \textit{Recall}) / (\text{Precisión} + \textit{Recall}) \tag{12}$$

Una vez conocidos los conceptos de precisión y *recall* y *f-score*, se muestran los cualitativos (inspección visual de las predicciones) y cuantitativos (valores de la precisión, *recall* y *f-score* de los dos apartados previos del resultado del aprendizaje en relación con las pruebas realizadas en imágenes térmicas de la FLIR ONE EDGE. En este estudio, se presentan los resultados obtenidos de los dos escenarios existentes. En primer lugar, se exponen los resultados del Escenario 1, es decir, el que trata de diferenciar entre defecto y no defecto, presentándose los casos externos antes de los internos. Posteriormente, se presentan los resultados del Escenario 2, donde se busca además diferenciar el tipo de defecto existente, siguiendo el mismo enfoque que en el primer escenario. Al final de este apartado, se compararán y discutirán los resultados cuantitativos obtenidos en la Tabla 4-1y la Tabla 4-2.

Comenzando con la Figura 4-8, de forma cualitativa se aprecia que el modelo detecta parte de la cornisa, que actúa como defecto, específicamente como puente térmico. De forma cuantitativa, abarca más de la mitad de la cornisa (*recall*), con un valor del 66,7 %, aunque le cuesta cuándo un puente térmico es oblicuo. La precisión es algo menor debido a la radiación del cielo (53,8 %). Aun así, se está en valores superiores al 50 %, siendo el promedio en torno al 60 % (59,5 % de *f-score*).

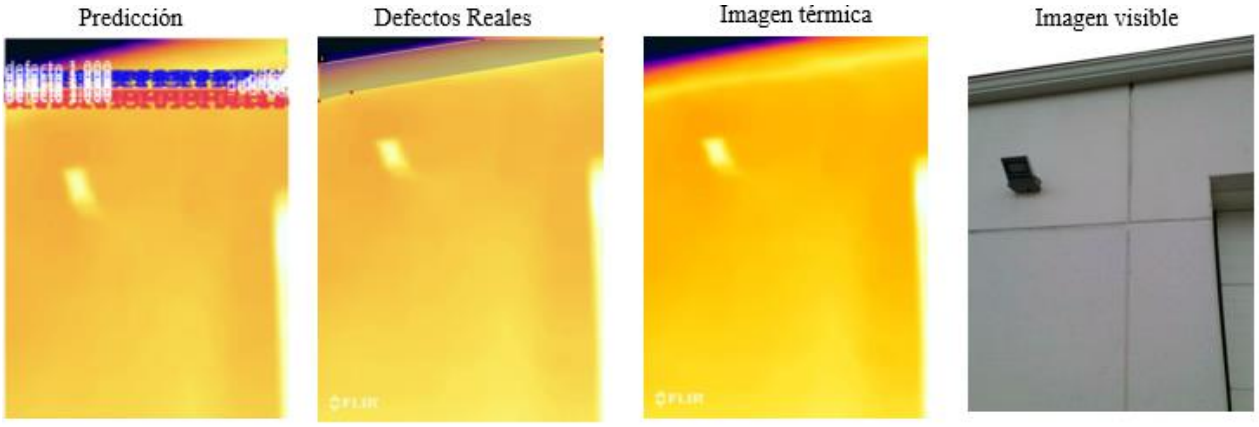


Figura 4-8 Resultados del Caso 1 (Zona 21) del Escenario 1 (Elaboración propia)

En la Figura 4-9, de forma cualitativa se aprecia que el modelo detecta parte de la cornisa y del alféizar, que actúan como defectos, específicamente como puentes térmicos. De forma cuantitativa, abarca la mitad de los defectos, ya que la grieta no la detecta, aunque prácticamente casi toda la cornisa y el alféizar, de ahí el valor próximo al 50 % del *recall* (49,7 %). La precisión es mayor detectando la cornisa entre plantas, y el alféizar, con respecto al caso anterior (70,8 %), probablemente porque aquí la cámara no abarca parte del cielo, perjudicando en las mediciones con su radiación si la cornisa es entre fachada y techo como en el caso previo (más difícil de calibrar la cámara). Con un valor del 58,4 % en *f-score*.

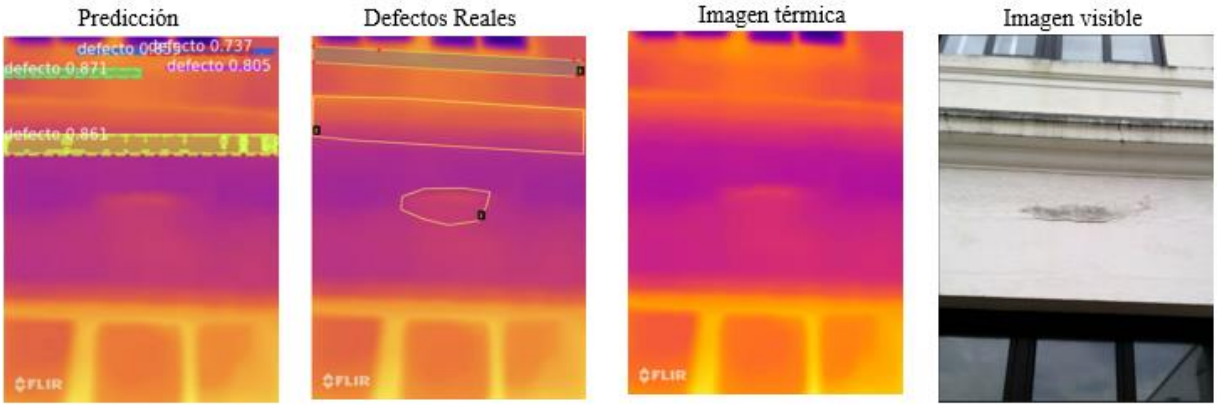


Figura 4-9 Resultados del Caso 2 (Zona 11) del Escenario 1 (Elaboración propia)

La última imagen del Escenario 1 en exteriores corresponde a la Figura 4-10, donde de forma cualitativa se aprecia que el modelo detecta toda la cornisa, que actúa como defecto específicamente como puente térmico. De forma cuantitativa, abarca prácticamente todo el puente térmico (con un valor de 76,6 % de *recall*) al no ser tan inclinado con una buena precisión (61,4 %), evitando en la captura de la imagen la radiación del cielo al ser la cornisa entre plantas. El promedio en este caso está en torno al 70 % (*f-score*).

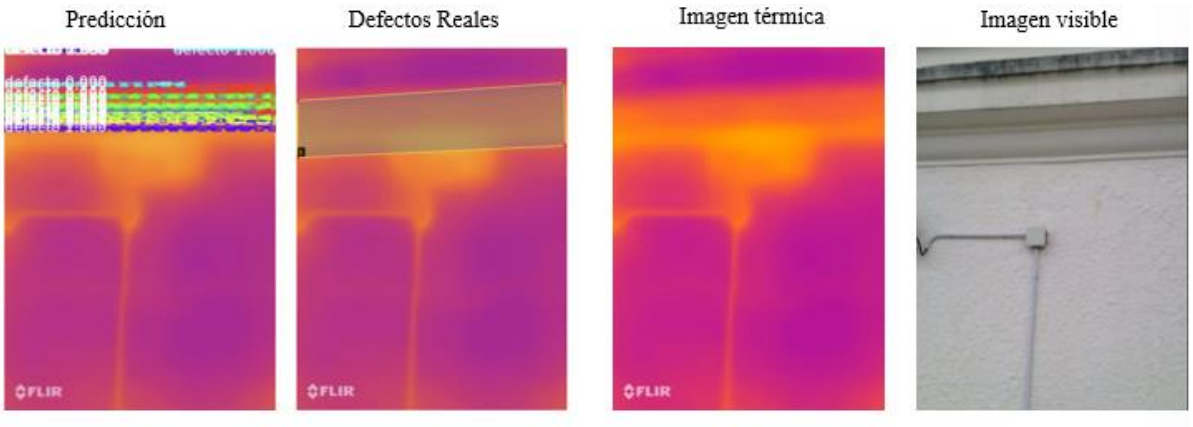


Figura 4-10 Resultados del Caso 3 (Zona 23) del Escenario 1 (Elaboración propia)

El primer caso correspondiente a interiores del Escenario 1 se trata de la Figura 4-11, en la sala multiusos. De forma cualitativa se aprecia que el modelo detecta parte de la junta entre falso techo y fachada, que actúa como defecto, específicamente como un puente térmico. De forma cuantitativa, la precisión es buena al no abarcar parte del cielo (75,1 %), aspecto del cielo que siempre estará oculto en inspecciones interiores como es este caso. De nuevo, al analizar el puente térmico demasiado inclinado, al modelo le cuesta más predecir toda su área (*recall*). Aun así, el *recall* tiene un valor de 48,5 %, cogiendo la mitad del área, y el *f-score* de 58,9 %.

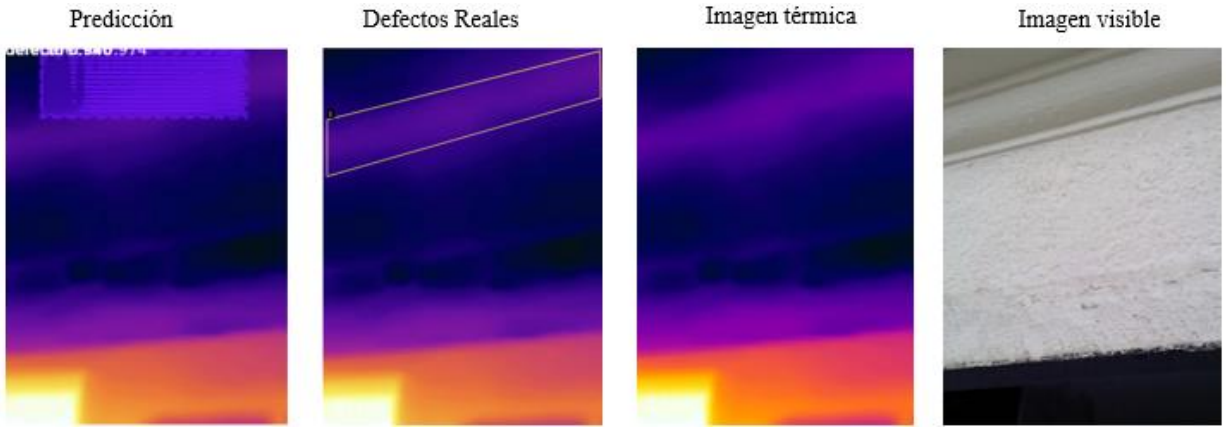


Figura 4-11 Resultados del Caso 4 (Zona 22) del Escenario 1 (Elaboración propia)

En cuanto a la Figura 4-12, de forma cualitativa se aprecia que el modelo detecta toda la junta entre falso techo y fachada, tratándose de un puente térmico. Por otro lado, no detecta la filtración de aire ni la humedad existentes. De forma cuantitativa, abarca prácticamente todo el puente térmico, aunque el valor del *recall* es bajo (23,3 %) ya que no abarca nada de la filtración de aire y de la humedad. En cuanto a la precisión, similar al caso de la Figura 4-8 con el cielo (Caso 1), en este caso se ve perjudicada probablemente por la complejidad de la zona interior, con muchos utensilios de distintos materiales en el laboratorio y por lo tanto diferentes radiaciones (diferentes emisividades), teniendo la ventana actuando de espejo, perdiendo así prestación el modelo a la hora de predecir defectos ya que se ve afectada la calibración de la cámara.

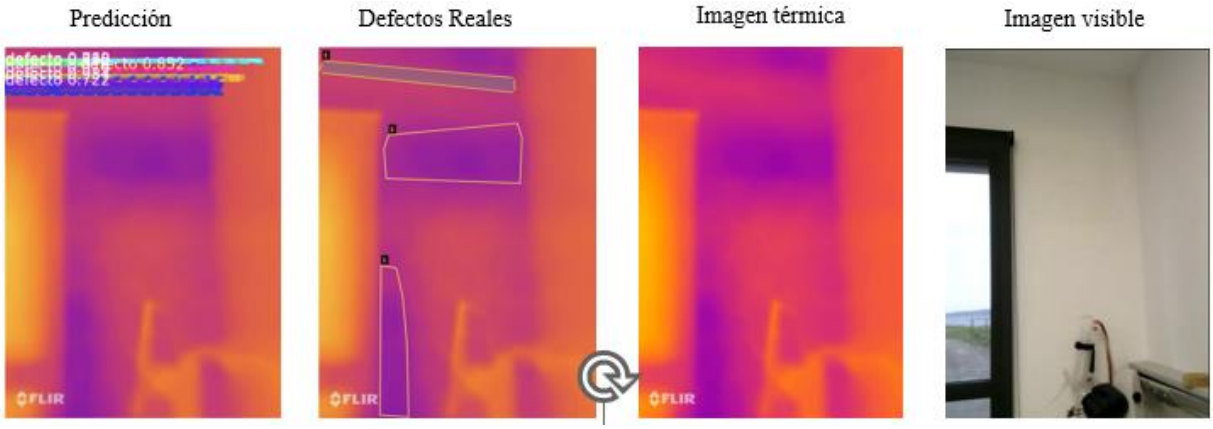


Figura 4-12 Resultados del Caso 5 (Zona 1) del Escenario 1 (activa) (Elaboración propia)

La Figura 4-13 es la misma ubicación que la Figura 4-12, pero en este caso obtenida de manera pasiva, por lo que el principal motivo de su análisis es la comparación entre las dos maneras de obtención de imágenes térmicas. Se aprecia que, comparado con la misma situación previa, usando pasiva el modelo funciona peor que la activa, ya que la segunda permite además de aumentar el banco de imágenes para el aprendizaje del modelo, una mejor predicción en las imágenes de testeo, ya que con la excitación térmica artificial se aumenta el contraste entre las regiones con defecto y las regiones sanas. Esto nos indica con alta certeza, que si se usase activa por fuera también se obtendrían mejores resultados, aunque no se ha hecho debido a la complicación de la infraestructura eléctrica para poder conectar las fuentes térmicas artificiales en el exterior. En este caso, no se calcula la precisión, *recall* y *f-score*, ya que este caso se usa para demostrar que la activa es mejor que la pasiva a la hora de predecir defectos.

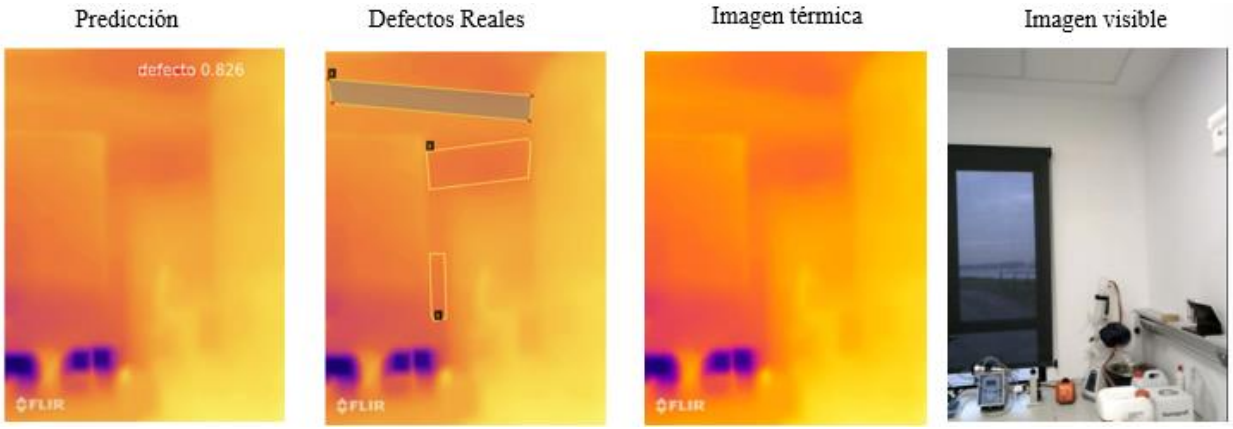


Figura 4-13 Resultados del Caso 5 (Zona 1) del Escenario 1 (pasiva) (Elaboración propia)

En la Figura 4-14, que se ubica en el laboratorio de mecánica, de forma cualitativa se aprecia que el modelo detecta en la columna una región inferior, el cual se relaciona a un defecto, en este caso a humedad por capilaridad. No obstante, no detecta una filtración de aire en el marco de la puerta de la nave, y una humedad por capilaridad en la fachada. De forma cuantitativa, abarca algo menos del total de los defectos (valor de *recall* del 42,2 %), ya que solo predice la humedad por capilaridad en la columna, y no la humedad por capilaridad en fachada y la filtración de aire. Hay que destacar que aquí la precisión también está por debajo del 50 % debido a que la filtración de aire no la predice por un pequeño desfase (41,9 %), tal y como se observa en las imágenes, siendo por lo tanto realmente no tan pobres los valores arrojados por los parámetros. Incluso así, el promedio está por encima del 40 % (valor de *f-score* 42,1 %).

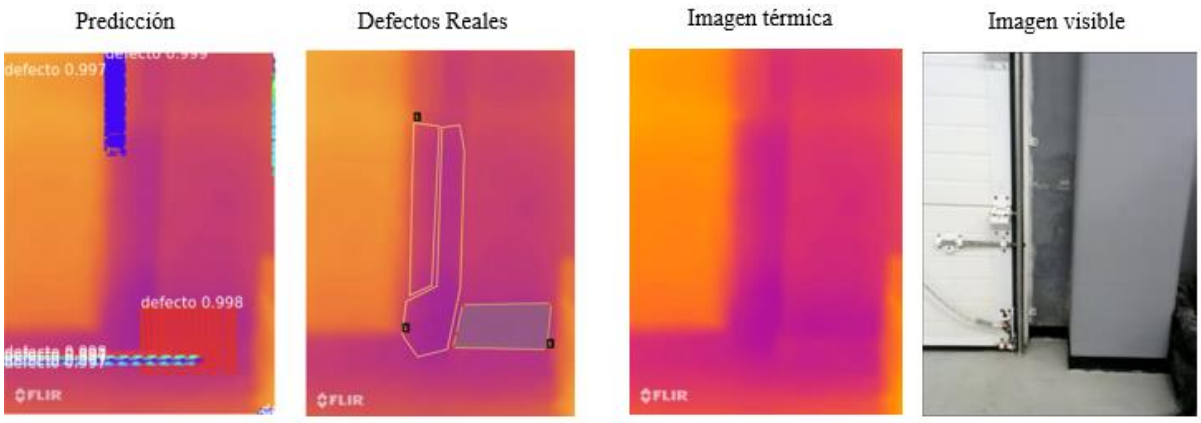


Figura 4-14 Resultados del Caso 6 (Zona 9) del Escenario 1 (activa) (Elaboración propia)

En la Figura 4-15, al igual que en el caso anterior, se observa que el modelo predice peor a través de las capturas de forma pasiva. De nuevo, aquí no se calcula la precisión, *recall* y *f-score*, ya que se usa este caso para demostrar que la activa es mejor que la pasiva a la hora de predecir defectos

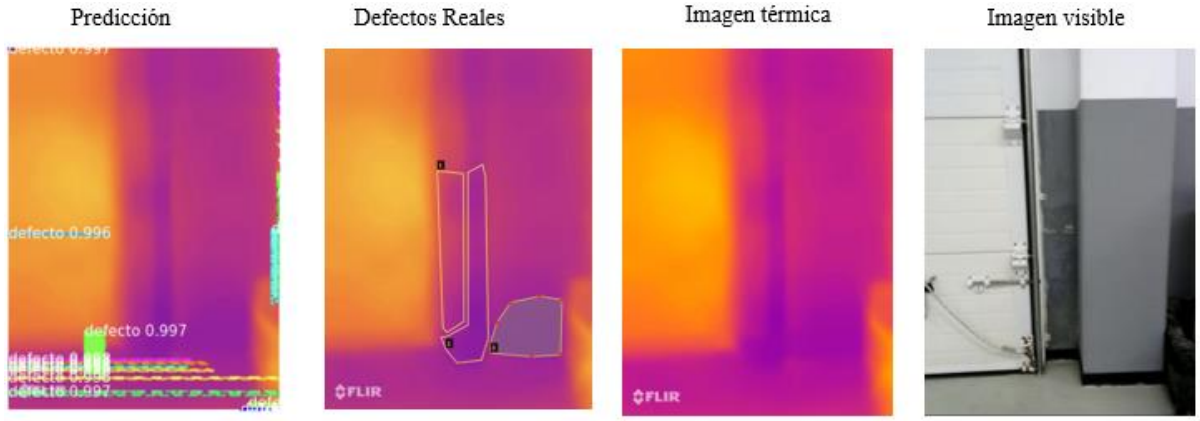


Figura 4-15 Resultados del Caso 6 (Zona 9) del Escenario 1 (pasiva) (Elaboración propia)

En la Figura 4-16, se presenta el primer caso del Escenario 2 desde exteriores en el que, de forma cualitativa, se aprecia que, a pesar de un cierto ruido, el modelo detecta los puentes térmicos en la cornisa entre plantas (las áreas más grandes predichas), lo cual es un resultado acertado. Cuantitativamente, el área abarcada no es grande (valor de *recall de* 12 %), pero la precisión es buena (58 %), además de acertar con la clasificación del defecto, es decir, puente térmico. Por lo tanto, aunque no indica toda el área del defecto, el modelo ofrece un indicio de su localización, acertando con la clasificación del defecto.

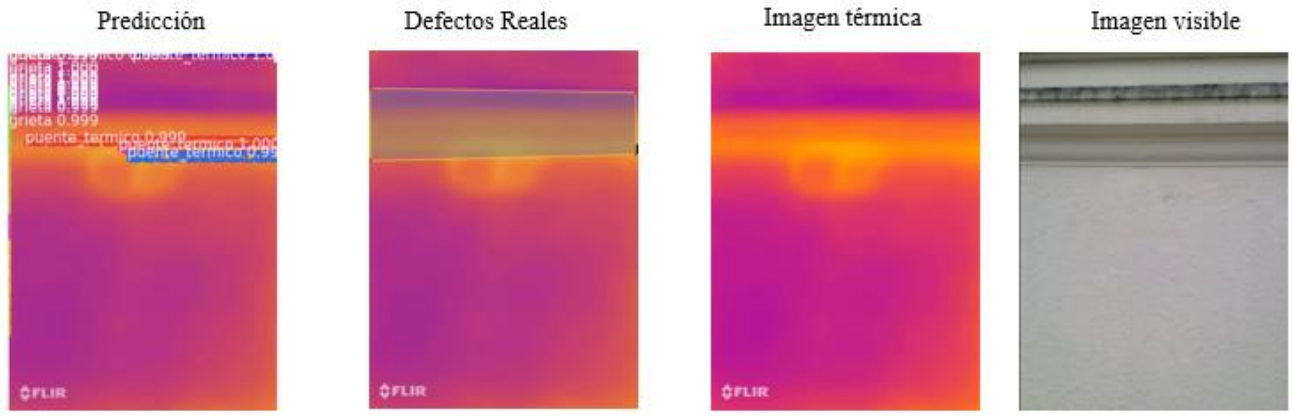


Figura 4-16 Resultados del Caso 7 (Zona 23) del Escenario 2 (Elaboración propia)

En cuanto a la Figura 4-17, de forma cualitativa, se observa que el modelo detecta parte del puente térmico en la cornisa entre plantas, aunque peor que en el Escenario 1, (ver Figura 4-10), lo cual resulta razonable viendo el resultado del aprendizaje de cada escenario (*loss train* y *loss val*). En el Escenario 2, resulta más complicado el aprendizaje ya se trata de clasificar el tipo de defecto además de realizar lo que hace el Escenario 1, es decir, indicar si existe un defecto o no en los pixeles de la imagen. Aun así, cuantitativamente, a pesar de un cierto ruido predicho, hay buenos valores de predicción (54 %), además de acertar con la clasificación del defecto, es decir, el puente térmico. Por tanto, aunque no indica toda el área del defecto (*recall* 5%), el modelo ofrece un indicio de su localización, acertando con la clasificación del defecto.

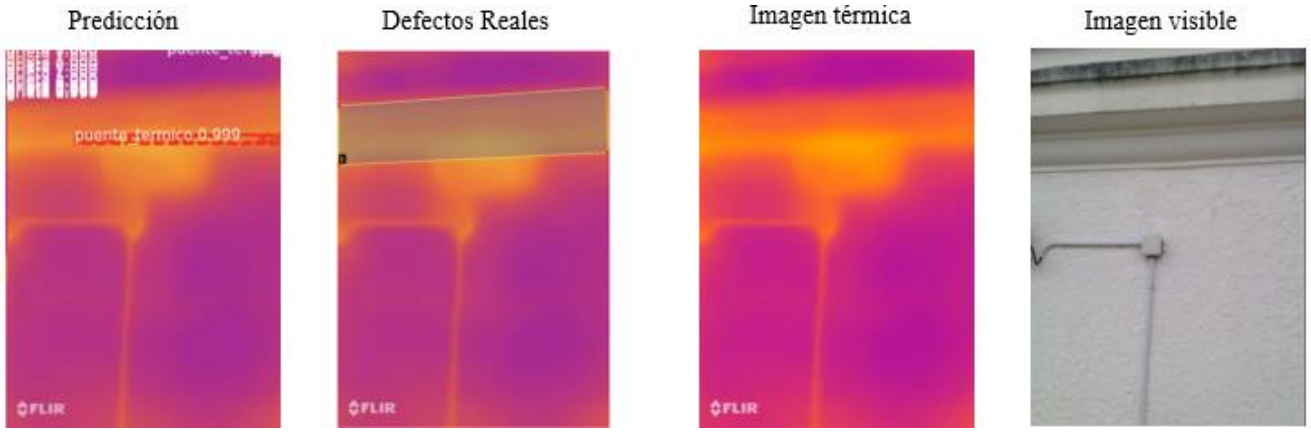


Figura 4-17 Resultados del Caso 8 (Zona 23) del Escenario 2 (Elaboración propia)

En la Figura 4-18, de forma cualitativa, se aprecia que el modelo detecta prácticamente todo el alféizar, aunque peor que en el Escenario 1 (ver Figura 4-9), ya que no detecta la cornisa entre plantas. Aun así, cuantitativamente, los valores de predicción (70,8 %) son similares al Escenario 1, además de acertar con la clasificación del defecto, que se trata de un puente térmico. Por lo tanto, y al igual que en el anterior caso, aunque no indica toda el área del defecto (*recall* 26 %), acierta con su clasificación.

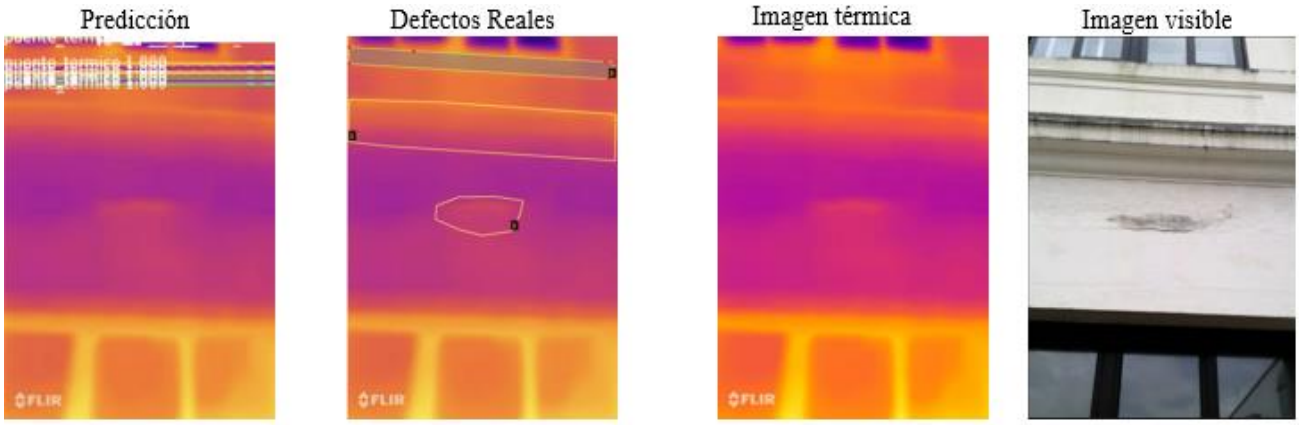


Figura 4-18 Resultados del Caso 9 del Escenario 2 (Elaboración propia)

Correspondiendo con el último caso en exteriores del Escenario 2 se encuentra la Figura 4-19. En esta, de forma cualitativa, se aprecia que el modelo detecta prácticamente en su totalidad la cornisa de la fachada, y nuevamente se presenta un resultado peor comparado con el Escenario 1 (ver Figura 4-8), ya que no detecta tanto área (*recall* 58,7 %), aunque es ligeramente mejor en la precisión (55,1 %). Cuantitativamente, los valores son aceptables, ya que acierta la clasificación del defecto, que se trata de un puente térmico.

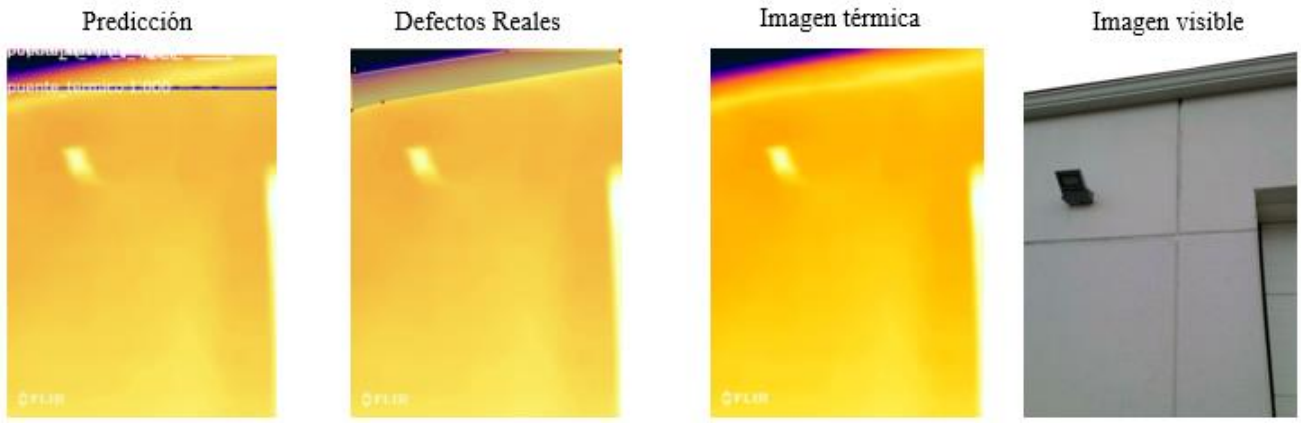


Figura 4-19 Resultados del Caso 10 (Zona 21) del Escenario 2 (Elaboración propia)

La Figura 4-20 corresponde al primer caso en interiores del Escenario 2. En este caso, de forma cualitativa, se aprecia que el modelo detecta parte del borde de la columna, además de un cierto ruido en la imagen. En el borde se aprecia que tiene un pequeño desprendimiento de material por eflorescencia, proceso químico que involucra la disolución de una sal retenida internamente en agua. Por lo tanto, la clasificación dada en la predicción de mayor área (región rosa) es correcta, ya que asigna como humedad a dicha área, siendo la zona donde más eflorescencia hay si se observa la imagen visible. Cuantitativamente, se refleja lo comentado en el aspecto cualitativo, no predice bien los defectos (*recall*), pero es aceptable (31 %), sobre todo si sólo se centra en el área predicha más grande, ya que acierta en el tipo de defecto, y en la región más afectada (más eflorescencia).

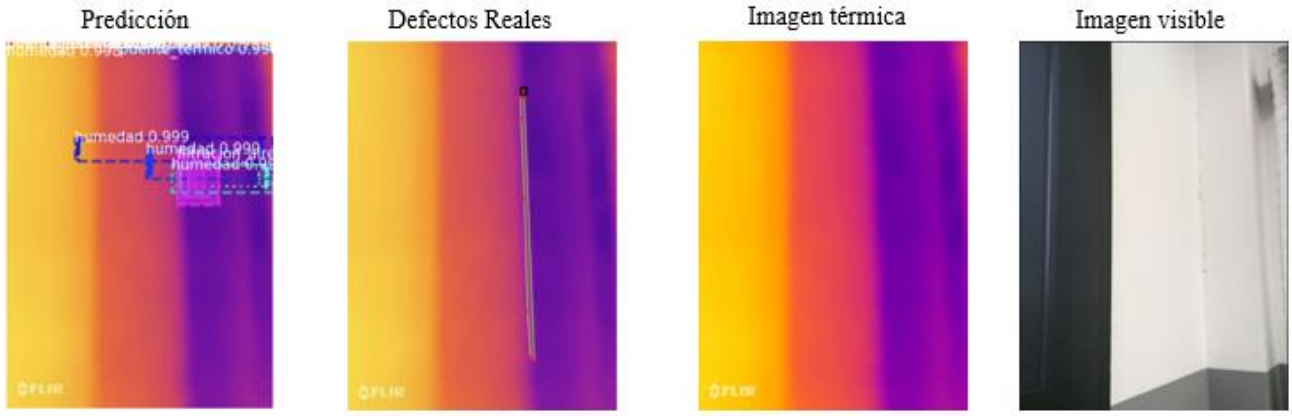


Figura 4-20 Resultados del Caso 11 (Zona 17) del Escenario 2 (Elaboración propia)

En la Figura 4-21 se vuelve al laboratorio de química, al igual que en la Figura 4-12 y la Figura 4-13. De forma cualitativa, se puede apreciar que el modelo detecta la unión entre pared y falso techo, es decir, el puente térmico, y lo clasifica correctamente. Comparando con el Escenario 1, da peor resultado que la activa del Escenario 1, pero mejor que la pasiva de ese mismo escenario. La precisión es de un 45,4 % y el *recall* de un 13,6%.

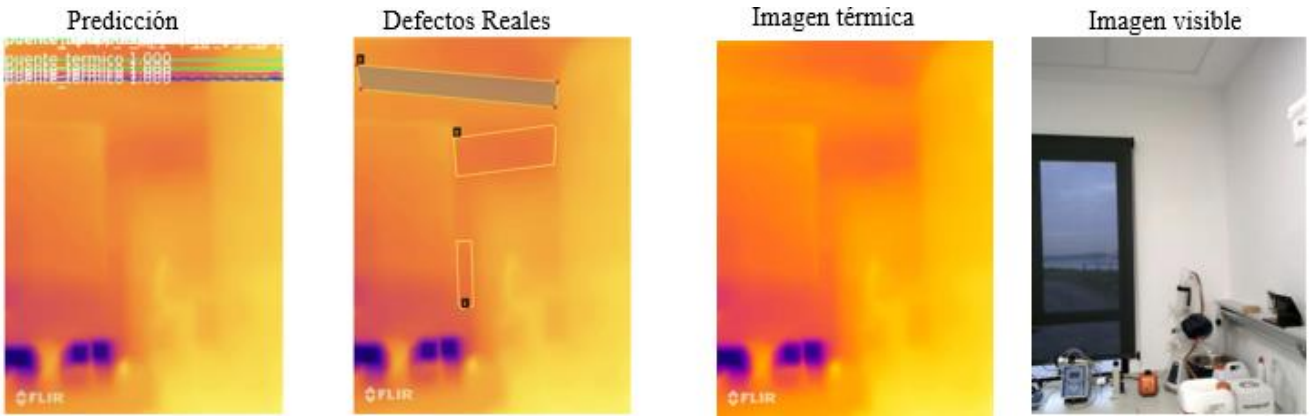


Figura 4-21 Resultados del Caso 12 (Zona 9) del Escenario 2 (activa) (Elaboración propia)

En la Figura 4-22, que se trata del laboratorio de mecánica y energía, de forma cualitativa, se aprecia que el modelo detecta la junta de la pared con el falso techo, de forma parcial, clasificando de forma correcta, aunque sea por varias áreas predichas, el puente térmico. Cuantitativamente, los valores son aceptables, superando todos los parámetros más del 50 %, con un 98,1 % de precisión, un 50,3 % de *recall* y un valor del 66,5 % de *f-score*.

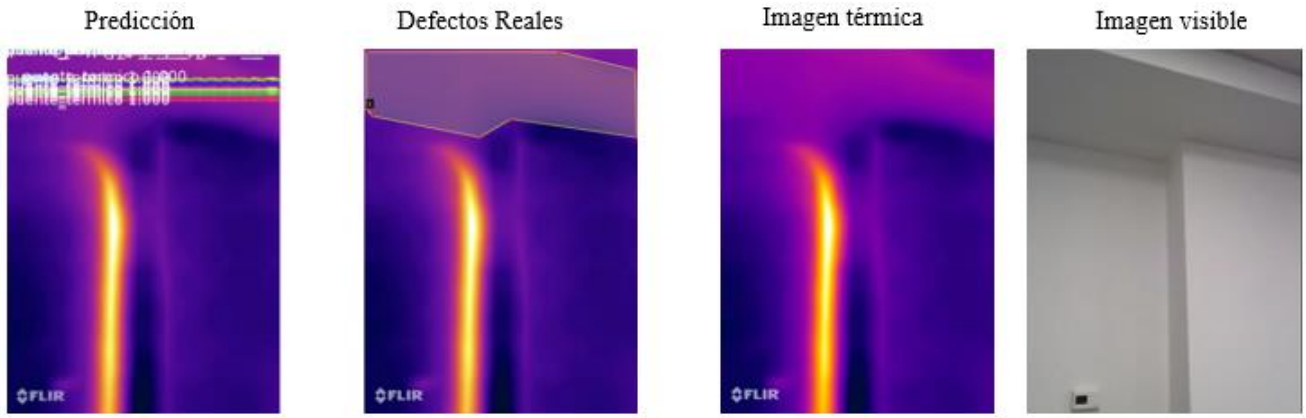


Figura 4-22 Resultados del Caso 13 (Zona 4) del Escenario 2 (activa) (Elaboración propia)

Por último, se resalta la necesidad de realizar más análisis en condiciones donde no haya puentes térmicos, para evaluar el modelo en diversos contextos. Se observa que su rendimiento tiende a favorecer la identificación de puentes térmicos, dejando en segundo plano otros tipos de defectos. Esto se debe a que los puentes térmicos tienden a tener el salto térmico más alto entre sus contornos y las proximidades de las regiones sanas, en comparación con otros tipos de defectos. Sin embargo, se señala que el modelo muestra una buena capacidad para identificar humedades, aunque este aspecto requiere un análisis más detallado en otros casos de estudio para confirmarlo. Sin el puente térmico, semeja que el modelo trabaja bien con las humedades, pero solo es un indicio que habría que seguir analizando en otros casos de estudio. A continuación, se muestran la Tabla 4-1 y la Tabla 4-2, donde se presentan los resultados de la precisión, *recall*, y *f-score* de los casos presentados anteriormente. La primera corresponde al Escenario 1 y la segunda al Escenario 2, haciendo una comparativa entre ellos y analizando los resultados.

Datos del testeo	**Precisión (%)**	***Recall* (%)**	***F-score* (%)**
Caso 1	53,8	66,7	59,5
Caso 2	70,8	49,7	58,4
Caso 4	75,1	48,5	58,9
Caso 3	61,4	76,6	68,2
Caso 5	47,6	23,3	31,3
Caso 6	41,9	42,2	42,1
Porcentaje global	58,4	51,1	53,1

Tabla 4-1 Resultados diferenciando entre defecto y no defecto (Elaboración propia)

La Tabla 4-1 no tiene en cuenta la clasificación del tipo de defecto, (solo entre defecto y sin defecto) mientras que la Tabla 4-2 sí tiene en cuenta el tipo de defecto al contar los verdaderos positivos, falsos positivos y falsos negativos en cada ROI del conjunto de datos de prueba.

Datos del testeo	**Precisión (%)**	***Recall* (%)**	***F-score* (%)**
Caso 11	48,8	31	37,9
Caso 7	58	12	20,2
Caso 8	54	5	9
Caso 9	70,8	26	38,1
Caso 10	55,1	58,7	56,8
Caso 12	45,4	13,6	21
Caso 13	98,1	50,3	66,5
Porcentaje global	61,4	28,1	35,6

Tabla 4-2 Resultados diferenciando los diferentes tipos de defectos (Elaboración propia)

Como se puede observar, el valor medio de la precisión está en torno al 60 %, llegando a valores por encima del 70 % en el Escenario 1, e incluso a casi un 100 % en un resultado del Escenario 2, demostrando que el modelo es preciso tanto detectando entre defectos y no defectos, y entre los

diferentes tipos de defectos. En donde ofrece peores resultados es cuando la imagen térmica captura parte del cielo en exteriores, o bien en interiores cuando captura parte de la ventana junto con un entorno interior en el que alberga varios objetos de distintas emisividades.

En cuanto al *recall*, es aquí donde se ve una mayor diferencia de resultados entre ambos escenarios. Mientras que en el Escenario 1, el valor del *recall* está en torno al 50 %, en el Escenario 2 no alcanza el 30 %. En el primer escenario, aunque el porcentaje no sea excesivamente alto, demuestra un progreso notable en la automatización de la identificación inicial de problemas en las imágenes térmicas. Por otro lado, en el segundo escenario, aunque el porcentaje de *recall* sea menor que en el primer escenario, sigue siendo un avance valioso, ya que se clasifica correctamente el tipo de defecto. Este menor *recall* puede deberse a la complejidad de diferenciar entre varios tipos de defectos en las imágenes térmicas, lo que requiere un análisis más detallado y posiblemente la incorporación de técnicas adicionales para mejorar la identificación de patrones específicos asociados con cada tipo de defecto, además de aumentar el banco de imágenes térmicas de entrada al aprendizaje del modelo de DL. Además, se aprecia que el *recall* empeora cuando se capturan los puentes térmicos en las imágenes demasiado inclinados.

Finalmente, en cuanto al *f-score*, en el primer escenario, con más de un 50 % de media, se observa la capacidad del modelo para identificar los defectos en comparación con la aleatoriedad. Este f-score tiene en cuenta tanto la precisión como el *recall* del modelo, lo que indica una capacidad balanceada para identificar los falsos positivos y negativos. Por otro lado, en el segundo escenario, donde alcanza un 35 %, y aunque el porcentaje sea menor, se trata de un resultado coherente, ya que el abanico de posibilidades en este escenario es mayor y aporta mayor complejidad al modelo. Asimismo, se aprecia mejores predicciones cuando las imágenes son adquiridas en modo activo frente al modo pasivo en ambos escenarios. De este modo, se concluye que ambos modelos aprendidos sirven para la identificación inicial y temprana de defectos constructivos en edificios usando imágenes térmicas de cámaras termográficas *low cost*. Con esa identificación, permite al usuario darle una primera idea del estado de salud de un edificio de forma automatizada, empleando posteriormente otros equipos que estime pertinente.

5 CONCLUSIONES Y LÍNEAS FUTURAS

5.1 Cumplimiento de los objetivos propuestos

En este Trabajo Fin de Grado se hace hincapié en la importancia de la prevención y conservación de los edificios para cumplir los objetivos de la Agenda 2030. Para ello, se trabajó con la técnica no destructiva de la termografía infrarroja, con el fin de dominar su uso. Asimismo, se implementaron algoritmos de aprendizaje profundo (*deep learning*) para la identificación automatizada de defectos constructivos a partir de las imágenes térmicas adquiridas con la técnica mencionada previamente. Para ello, se emplearon dos cámaras termográficas (alta gama y *low cost*) para comparar sus prestaciones en las imágenes adquiridas mediante sus introducciones a los modelos de *deep learning* utilizados. Al mismo tiempo, se capturaron imágenes en los dos modos de adquisición existentes: activa y pasiva.

Los objetivos citados son contemplados en el apartado 1.2, siendo el uso de cámaras termográficas *low cost* y la combinación de activa y pasiva novedosos en el campo de la termografía infrarroja a la hora de usar modelos de *deep learning*, según el estado del arte (apartado 2.4). Como valor añadido, se trata de identificar 4 tipos de defectos constructivos diferentes, cifra no alcanzada hasta el momento, que son: puentes térmicos, humedades, grietas y filtraciones de aire.

Para el desarrollo del trabajo, se ha adquirido un conocimiento profundo sobre la termografía infrarroja, comprendiendo su funcionamiento, aplicaciones y limitaciones (apartado 2.2). Además, a través de la práctica y la investigación, se ha logrado un nivel de dominio que permite aplicar esta técnica de manera efectiva en el análisis de edificios. Por otra parte, se ha realizado un exhaustivo estudio sobre los fundamentos y modelos de *deep learning*, y sus aplicaciones en la identificación automatizada de defectos constructivos a través de las imágenes térmicas obtenidas mediante las cámaras termográficas (apartados 2.3 y 2.4).

En el aspecto práctico, se han empleado dos cámaras termográficas en este trabajo, la FLIR E85 (alta gama) y la FLIR ONE EDGE (bajo coste, *low cost*), considerando sus especificaciones técnicas, pero sobre todo por ser de diferentes gamas que permita analizar la calidad frente al precio para el uso que se quiere dar en este contexto (apartado 3.1). La captura de las imágenes térmicas fue en el edificio de investigación del CUD-ENM, dado el estado de deterioro avanzado en varias secciones constructivas (apartado 3.1), escogiendo las paredes de mayor interés mediante una inspección visual previa y aplicando los dos modos de adquisición: activa y pasiva (apartados 3.2 y 3.3). A través de las diferentes imágenes térmicas obtenidas, se han identificado las regiones de los posibles defectos constructivos a partir de sus huellas térmicas, mediante un etiquetado necesario para el correcto funcionamiento de los modelos de *deep learning* seleccionados (apartado 3.4). El modelo de deep learning seleccionado fue el modelo conocido como Mask R-CNN, Mask *Region-based Convolutional Neural Network,* dado su alta prestación ante las instancias de objetos frente a otros modelos equivalentes, es decir, frente a la

clasificación, delimitación de la localización y segmentación de objetos en imágenes [57] (apartado 3.5). Para ello, se ha explicado cómo se realiza el aprendizaje y cómo se enfoca la prestación del modelo tras su aprendizaje (apartado 3.6) junto al código empleado para su uso (apartado 3.8).

En cuanto a los resultados, se mostró el aprendizaje del modelo seleccionado en dos escenarios diferentes. El primer escenario consistió en que el modelo fuese capaz en diferenciar entre regiones sanas y con defectos, y el segundo escenario, a mayores, clasificar el tipo de defecto (apartado 4.1). Tras el aprendizaje, el modelo aprendido hizo predicciones a un nuevo banco de imágenes, cuantificando su prestación. (apartado 4.2).

Se puede afirmar, tras el trabajo, que el aprendizaje del modelo fue aceptable en ambos escenarios, a pesar de tener un banco de imágenes reducido como datos de entrada. Esto se demuestra por la prestación de dicho modelo aprendido en las predicciones estimadas en las imágenes de testeo. Dado la baja calidad de las imágenes térmicas de la cámara *low cost* frente a la cámara de alta gama, se ha considerado utilizar las imágenes de mejor calidad para el aprendizaje del modelo, y las de la cámara *low cost* para el testeo, tras dicho aprendizaje. De este modo, se presenta un sistema automatizado de detección de defectos constructivos a partir de cámaras térmicas con un precio asequible para toda la población, ya que el modelo aprendido no lo hay que volver a aprender. Tal y como se aprecia en el apartado 4.2, las métricas arrojadas son lo suficientemente buenas para permitir al usuario darle una primera idea del estado de salud de un edificio de forma automatizada, empleando posteriormente otros equipos que estime pertinente, valores métricas muy semejante a trabajos de investigación dentro del mismo ámbito [48].

5.2 Desafíos y líneas futuras de investigación

A pesar de los avances significativos logrados, este estudio reconoce varios desafíos que requieren atención continua y áreas prometedoras para futuras investigaciones en el campo de la identificación automatizada de defectos constructivos en edificios a partir de la termografía infrarroja y el *deep learning*.

El primer desafío consiste en la ampliación del conjunto de datos de entrada. Una de las mayores limitaciones a las que el trabajo se ha visto expuesto, ha sido la escasez de datos de entrada debido al reducido espacio de investigación disponible en el objeto de estudio. Una línea futura de investigación sería la expansión a otras ubicaciones para poder mejorar el conjunto de datos utilizados para entrenar y validar el modelo de *deep learning*, y así mejorar el aprendizaje.

Un segundo desafío sería la exploración de enfoques multimodales. Se puede explorar la combinación de datos obtenidos de múltiples fuentes, no solo de las cámaras termográficas, esto es, imágenes visibles o de otra banda espectrales que mejorarían la identificación de defectos constructivos. Esta integración podría proporcionar una visión más completa y precisa del estado de los diferentes edificios.

Un tercer desafío, sería contemplar el uso de otros modelos de *deep learning*, comparando entre ellos sus prestaciones para el ámbito de estudio en cuestión.

Asimismo, como cuarto desafío estaría llevar el ámbito de este TFG a otros sectores que no sea la edificación, entre otros, al patrimonio cultural y a la infraestructura civil.

Como quinto, y último desafío a subrayar, una buena opción para mejorar el aprendizaje del modelo de *deep learning* en el futuro, consistiría en aplicar algoritmos de filtrado de ruido en las imágenes térmicas antes de sus usos para dicho aprendizaje.

6 BIBLIOGRAFÍA

[1] S.-A. Keo, D. Defer, F. Breaban, y F. Brachelet, «Comparison between Microwave Infrared Thermography and CO₂ Laser Infrared Thermography in Defect Detection in Applications with CFRP», Mater. Sci. Appl., vol. 04, n.o 10, pp. 600-605, 2013, doi: 10.4236/msa.2013.410074.

[2] R. Usamentiaga, P. Venegas, J. Guerediaga, L. Vega, J. Molleda, y F. Bulnes, «Infrared Thermography for Temperature Measurement and Non-Destructive Testing», Sensors, vol. 14, n.o 7, pp. 12305-12348, jul. 2014, doi: 10.3390/s140712305.

[3] I. Garrido, S. Lagüela, y P. Arias, «Autonomous thermography: towards the automatic detection and classification of building pathologies», en Proceedings of the 2018 International Conference on Quantitative InfraRed Thermography, QIRT Council, 2018. doi: 10.21611/qirt.2018.022.

[4] J.A. De Almeida. «Técnicas de Diagnóstico de Patologias Em Edificios.pdf», 2010

[5] «Guía de la termografía infrarroja.pdf», 2011.

[6] M. Garvía, «Tema: Imagen y Televisión», 2012.

[7] «Espectro electromagnético». [En línea]. Disponible en: https://adrianredesdedatos.blogspot.com/2018/09/espectro-electromagnetico.html, Accesed on January 26 2024

[8] W. Minkina, «Theoretical basics of radiant heat transfer – practical examples of calculation for the infrared (IR) used in infrared thermography measurements», 2021. [En línea]. Disponible en: https://doi.org/10.1080/17686733.2020.1738164

[9] M. Carosena, «Infrared thermography: Recent advances and future», 2012. [En línea]. Disponible en: 10.2174/97816080514341120101

[10] «Ley de Planck». [En línea]. Disponible en: https://geocities.ws/climmarsal/Ley_de_Planck.html, Accesed on February 02 2024

[11] «Ley de Stefan-Boltzman». [En línea]. Disponible en: https://www.researchgate.net/figure/Stefan-Boltzmann-law-power-radiated-by-a-greybody-with-different-emissivities_fig1_263862713, Accesed on February 02 2024

[12] «Captación cámara termográfica». [En línea]. Disponible en: chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://www.juanpalacios.es/wp-content/uploads/2015/12/servicio-analisis-termografico.pdf, Accesed on February 04 2024

[13] J. Sarola, «Sir Frederick William Herschel, descubridor de la luz infrarroja»., 2020 [En línea]. Disponible en: https://nirs-research.com/es/sir-frederick-william-herschel-discoverer-of-the-light-infraroja/

[14] «Historia de la termografía». [En línea]. Disponible en: https://termografias.mx/2015/12/17/historia-termografia/, Accesed on February 12 2024

[15] P. Cabeza, « Estudio patológico de humedades por medio de la termografía», 2019. [En línea]. Disponible en: www.interempresas.net/Plas

[16] R. Gade y T. B. Moeslund, «Thermal cameras and applications: a survey», Mach. Vis. Appl., vol. 25, n.o 1, pp. 245-262, ene. 2014, doi: 10.1007/s00138-013-0570-5.

[17] «La cámara termográfica». [En línea]. Disponible en: https://www.prolisur.com/noticias/termografia-infrarroja-el-gran-aliado-del-aislamiento-termico/, Accesed on February 12 2024

[18] «FLIR Technical Note», 2008.

[19] «Cámara termográfica». [En línea]. Disponible en: https://www.kin.energy/blogs/post/termograf%C3%ADa-un-aliado-en-el-ahorro-de-energ%C3%ADa, Accesed on February 12 2024

[20] M. Rodríguez Martín, S. Lagüela Lopez, D. Gonzalez Aguilera, y L. Diaz Vilariño, «TERMOGRAFÍA ACTIVA, PARTE 1: ENFOQUE TEÓRICO DE LA CAPTACIÓN INFRARROJA, PROCESAMIENTO DE DATOS Y CLASIFICACION», DYNA Ing. E Ind., vol. 90, n.o 3, pp. 456-460, 2015, doi: 10.6036/7556.

[21] C. Ibarra-Castanedo, J. R. Tarpani, y X. P. V. Maldague, «Nondestructive testing with thermography», Eur. J. Phys., vol. 34, n.o 6, pp. S91-S109, nov. 2013, doi: 10.1088/0143-0807/34/6/S91.

[22] R. Usamentiaga, «Real-time adaptive method for noise filtering of a stream of thermographic line scans based on spatial overlapping and edge detection», J. Electron. Imaging, vol. 17, n.o 3, p. 033012, jul. 2008, doi: 10.1117/1.2952844.

[23] D. Wu, G. Busse, y W. Karpen, «Thermal wave imaging with phase sensitive modulated thermography». 1992. [En línea]. Disponible en: https://doi.org/10.1063/1.351366

[24] «Foco halógeno utilizado en termografía activa». [En línea]. Disponible en: https://bigmatmijas.com/producto/foco-halogeno-500-w-con-lampara-400-w-ahorro/, Accesed on Februay 12 2024

[25] R. S. Pérez, M. V. Márquez-Olivera, y O. Sánchez-García, «DESARROLLO DE UNA BASE DE DATOS CON IMÁGENES TERMOGRÁFICAS PARA USO EN ALGORITMOS DE VISIÓN E INTELIGENCIA ARTIFICIAL», vol. 39, n.o 125, 2017.

[26] «Automatización de procesos». [En línea]. Disponible en: https://www.gb-advisors.com/es/automatizacion-de-procesos/Accesed on February 20 2024

[27] «Artificial intelligence 101 things you must know today about our future». [En línea]. Disponible en: https://www.amazon.es/Artificial-Intelligence-Things-Today-Future/dp/1982048808, Accesed on Februay 20 2024

[28] «Imitando al cerebro. Redes neuronales.» [En línea]. Disponible en: https://libros.catedu.es/books/la-ia-en-educacion-una-aproximacion-practica/page/unidad-24-imitando-al-cerebro-redes-neuronales, Accesed on 22 February 2024

[29] «Shallow Neutral Networks». [En línea]. Disponible en: https://towardsdatascience.com/shallow-neural-networks-23594aa97a5, Accesed on February 26 2024

[30] «Funcionamiento simplificado de una neurona». [En línea]. Disponible en: https://becominghuman.ai/understanding-neural-networks-1-the-concept-of-neurons-287be36d40f, Accesed on Februay 26 2024

[31] J. I. B. Fernández, «Elaboración de un modelo NER para su uso en aplicaciones NLP», 2020.

[32] «¿Qué es Red neuronal feedforward?» [En línea]. Disponible en: https://gamco.es/glosario/red-neuronal-feedforward/Accesed on March 02

[33] I. Garrido et al., «Introduction of Deep Learning in Thermographic Monitoring of Cultural Heritage and Improvement by Automatic Thermogram Pre-Processing Algorithms», Sensors, vol. 21, n.o 3, p. 750, ene. 2021, doi: 10.3390/s21030750.

[34] A. Obuchowski, «The concept of neurons». [En línea]. Disponible en: https://becominghuman.ai/understanding-neural-networks-1-the-concept-of-neurons-287be36d40f, 2019

[35] E. Anguiano-Hernandez, «Naive Bayes Multinomial para Clasificacio´n de Texto Usando un Esquema de Pesado por Clases», 2009.

[36] «Machine Learning & Deep Learning». [En línea]. Disponible en: https://www.iic.uam.es/inteligencia-artificial/machine-learning-deep-learning/, Accesed on March 10

[37] J. R. R. Garcia, «POTENCIALIDADES DA TERMOGRAFIA PARA O DIAGNÓSTICO DE PATOLOGIAS EM EDIFÍCIOS», 2014.

[38] «Termografía aplicada a las edificaciones». [En línea]. Disponible en: https://peritojudicial.com/estudio-termografico/, Accesed on February 20 2024

[39] I. Danielski y M. Fröling, «In Situ Measurements of Thermal Properties of Building Fabrics Using Thermography under Non-Steady State Heat Flow Conditions», Infrastructures, vol. 3, n.o 3, p. 20, jul. 2018, doi: 10.3390/infrastructures3030020.

[40] B. Tejedor, M. Casals, M. Gangolells, y X. Roca, «Quantitative internal infrared thermography for determining in-situ thermal behaviour of façades», Energy Build., vol. 151, pp. 187-197, sep. 2017, doi: 10.1016/j.enbuild.2017.06.040.

[41] I. Garrido, S. Lagüela, P. Arias, y J. Balado, «Thermal-based analysis for the automatic detection and characterization of thermal bridges in buildings», Energy Build., vol. 158, pp. 1358-1367, ene. 2018, doi: 10.1016/j.enbuild.2017.11.031.

[42] E. Edis, I. Flores-Colen, y J. De Brito, «Quasi-quantitative infrared thermographic detection of moisture variation in facades with adhered ceramic cladding using principal component analysis», Build. Environ., vol. 94, pp. 97-108, dic. 2015, doi: 10.1016/j.buildenv.2015.07.027.

[43] C. Lerma, E. Barreira, y R. M. S. F. Almeida, «A discussion concerning active infrared thermography in the evaluation of buildings air infiltration», Energy Build., vol. 168, pp. 56-66, jun. 2018, doi: 10.1016/j.enbuild.2018.02.050.

[44] J. R. M.-D. Dios y A. Ollero, «Automatic Detection of Windows Thermal Heat Losses in Buildings Using UAVs», en 2006 World Automation Congress, Budapest, Hungary: IEEE, jul. 2006, pp. 1-6. doi: 10.1109/WAC.2006.375998.

[45] P. G. Angaitkar, K. Saxena, N. Gupta, y A. Sinhal, «Enhancement of infrared image for roof leakage detection», en 2013 IEEE International Conference ON Emerging Trends in Computing, Communication and Nanotechnology (ICECCN), Tirunelveli: IEEE, mar. 2013, pp. 580-585. doi: 10.1109/ICE-CCN.2013.6528566.

[46] D. Gertsvolf, M. Horvat, D. Aslam, A. Khademi, y U. Berardi, «A U-net convolutional neural network deep learning model application for identification of energy loss in infrared thermographic images», Appl. Energy, vol. 360, p. 122696, abr. 2024, doi: 10.1016/j.apenergy.2024.122696.

[47] L. C. M. Dafico, E. Barreira, R. M. S. F. Almeida, y R. Vicente, «Machine learning models applied to moisture assessment in building materials», Constr. Build. Mater., vol. 405, p. 133330, nov. 2023, doi: 10.1016/j.conbuildmat.2023.133330.

[48] I. Garrido, S. Lagüela, Q. Fang, y P. Arias, «Introduction of the combination of thermal fundamentals and Deep Learning for the automatic thermographic inspection of thermal bridges and water-related problems in infrastructures», Quant. InfraRed Thermogr. J., vol. 20, n.o 5, pp. 231-255, oct. 2023, doi: 10.1080/17686733.2022.2060545.

[49] I. Garrido, S. Lagüela, R. Otero, y P. Arias, «Thermographic methodologies used in infrastructure inspection: A review—data acquisition procedures», Infrared Phys. Technol., vol. 111, p. 103481, dic. 2020, doi: 10.1016/j.infrared.2020.103481.

[50] «Edificio de Investigación CUD-ENM», [En línea]. Disponible en: https://cud.uvigo.es/edificio-de-investigacion/, Accesed on Februay 26 2024

[51] «Clima de Pontevedra». [En línea]. Disponible en: https://climaytiempo.es/espana/pontevedra-3543138/Accesed on February 24 2024

[52] «EXX-Series-MFG-Datasheet-US.pdf», 2019

[53] «FLIR E85». [En línea]. Disponible en: https://www.flir.es/support/products/e85/#Overview, Accesed on February 16 2024

[54] «FLIR ONE EDGE». [En línea]. Disponible en: https://www.flir.com.mx/products/flir-one-edge/?vertical=condition+monitoring&segment=solutions, Accesed on February 16 2024

[55] «Cámara FLIR ONE EDGE». [En línea]. Disponible en: https://www.flir.es/products/flir-one-edge-pro/, Accesed on February 16 2024

[56] «VIA_HTML». [En línea]. Disponible en: https://www.robots.ox.ac.uk/~vgg/software/via/via.html, Accesed on March 12 2024

[57] V. Sampath, I. Maurtua, J. J. Aguilar Martín, y A. Gutierrez, «A survey on generative adversarial networks for imbalance problems in computer vision tasks», J. Big Data, vol. 8, n.o 1, p. 27, dic. 2021, doi: 10.1186/s40537-021-00414-0.

[58] «R-CNN vs Fast R-CNN vs Faster R-CNN – A Comparative Guide». [En línea]. Disponible en: https://analyticsindiamag.com/r-cnn-vs-fast-r-cnn-vs-faster-r-cnn-a-comparative-guide/, Accesed on March 12 2024

[59] «Mask R-CNN with TensorFlow 2 on Windows 10». [En línea]. Disponible en: https://www.immersivelimit.com/tutorials/mask-rcnn-for-windows-10-tensorflow-2-cuda-101

[60] K. He, X. Zhang, S. Ren, J. Sun «Deep Residual Learning for Image Recognition.pdf»,2015 .

[61] «¿Qué es el transfer learning y qué ventajas tiene?» [En línea]. Disponible en: https://www.unir.net/ingenieria/revista/transfer-learning/, Accesed on March 18 2024

[62] «¿Qué es el Gradiente Descendente?» [En línea]. Disponible en: https://www.codificandobits.com/blog/el-gradiente-descendente/, Accesed on March 18 2024

[63] «Mask-R-CNN-using-Tensorflow2». [En línea]. Disponible en: https://github.com/AarohiSingla/Mask-R-CNN-using-Tensorflow2, Accesed on March 22 2024

[64] «Precision & recall». [En línea]. Disponible en: https://medium.com/@gogasca_/precisi%C3%B3n-y-recuperaci%C3%B3n-precision-recall-dc3c92178d5b, Accesed on March 22 2024

ANEXO I: IMPLICACIONES SOCIALES, Y/O ECONÓMICAS, Y/O AMBIENTALES

ASPECTOS AMBIENTALES

La detección y reparación eficiente de defectos constructivos puede contribuir a la reducción del impacto ambiental asociado con la demolición y reconstrucción de estructuras afectadas, así como con la generación de residuos y la pérdida de recursos naturales.

Una de las principales ventajas del uso de tecnologías no destructivas para poder estudiar un edificio es la reducción de personal y maquinaria necesarios, lo cual reduce la cantidad de residuos generados durante el plazo de estudio y, además, elimina la generación de gases de efecto invernadero que se generan con el transporte y uso de la maquinaria. Además, la otra principal ventaja existente es que se reducen los daños materiales, contribuyendo a una economía circular más sostenible evitando la generación de residuos y la necesidad de reconstruir los materiales dañados.

Además, al optimizar el uso de recursos y minimizar la generación de residuos, la adopción de tecnologías de inspección avanzadas puede fomentar una cultura de responsabilidad ambiental y sostenibilidad en la industria de la construcción.

ASPECTOS ECONÓMICOS

La detección y corrección oportuna de defectos constructivos puede generar ahorros significativos en costos de mantenimiento y reparación a largo plazo, ya que gracias a la cámara termográfica se obtiene una información muy valiosa sobre el estado del edificio que no puede obtenerse a través de una inspección visual.

Por un lado, una de las principales ventajas que aporta el desarrollo de este proyecto es la prevención de averías, ya que mediante la detección temprana de las patologías con una simple inspección con la cámara termográfica ayuda a captar anomalías que pueden derivar en un problema serio para el edificio en cuestión y ahorrar los costes relacionados con la reparación de objetos y elementos constructivos.

Por otro lado, sirve también para la conservación del confort térmico y la reducción del consumo energético, gracias a la localización de los puntos donde se producen pérdidas de calor o problemas de aislamiento, entre otros, permitiendo adoptar las medidas necesarias para paliar estas pérdidas y reducir los costes en electricidad (véase Figura A1-1).

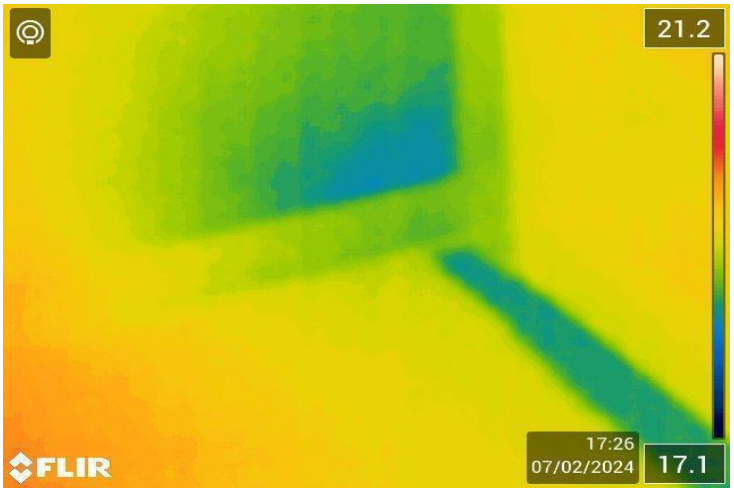


Figura A1-1 Filtración de aire rompiendo el aislamiento térmico (Elaboración propia)

Finalmente, a parte de estas 2 ventajas existen otras muchas entre las cuales se encuentran la mayor eficacia en la identificación de puntos calientes, optimizar las actividades que se llevan a cabo en el edificio y contribuir a la extensión de vida útil de los equipos que se encuentran en el interior.

ASPECTOS INDUSTRIALES

La incorporación de técnicas de *deep learning* en la detección automatizada de defectos constructivos, puede mejorar la competitividad y posición de mercado de las empresas del sector de la construcción, al aumentar la eficiencia y precisión de los procesos de inspección.

La investigación y desarrollo en este campo pueden impulsar la innovación y el avance tecnológico en la industria de la construcción, fomentando la adopción de soluciones más avanzadas y eficientes que mejoren la calidad y durabilidad de los edificios.

Además, se avanza hacia una industria más sostenible en concordancia con los objetivos de la Agenda 2030 al reducir el número de personal, maquinaria y residuos generados.

Finalmente, la colaboración entre empresas, instituciones académicas y organismos reguladores en proyectos de investigación y desarrollo, puede promover la transferencia de conocimientos y tecnologías, fortaleciendo así la capacidad de la industria para enfrentar los desafíos emergentes y adaptarse a las demandas del mercado.

ASPECTOS SOCIALES

La implementación de sistemas automatizados de detección de defectos constructivos puede mejorar significativamente la calidad de vida de las personas al garantizar la seguridad y habitabilidad de las edificaciones en las que viven, trabajan o transitan.

Además de los beneficios tangibles, como la prevención de accidentes y lesiones, la detección temprana de defectos constructivos también puede generar confianza y tranquilidad en la comunidad, contribuyendo así al bienestar emocional y psicológico de los ciudadanos.

La democratización de tecnologías de inspección avanzadas, como la termografía infrarroja *low cost*, puede reducir las disparidades sociales al brindar acceso a herramientas de seguridad y calidad a comunidades con recursos limitados.

ANEXO II: REFLEXIONES ÉTICAS Y SOCIALES

REFLEXIONES ÉTICAS Y SOCIALES EN LA MEMORIA DEL TFG

A lo largo del desarrollo del presente trabajo, se han abordado diversas reflexiones éticas y sociales que se han reflejado en las diferentes secciones. Estas reflexiones han surgido como resultado del análisis crítico de las implicaciones éticas y sociales asociadas con el uso de tecnologías de inspección automatizadas en el ámbito de la construcción.

REFLEXIÓN ÉTICA Y SOCIAL EN EL PLANO DEL TRABAJO DESARROLLADO

Si bien el enfoque principal del trabajo se ha centrado en el desarrollo y aplicación de sistemas automatizados de detección de defectos constructivos, es importante reconocer las implicaciones éticas y sociales inherentes a esta área de investigación. En este sentido, se plantea una reflexión sobre el impacto potencial del uso de tecnologías de inspección automatizadas en diversos aspectos de la sociedad y la industria de la construcción.

Desde una perspectiva ética, es fundamental considerar cómo el uso de sistemas automatizados de detección de defectos puede afectar a diferentes partes interesadas, incluidos los propietarios de edificios, los trabajadores de la construcción, los organismos reguladores y la comunidad en general. Se debe tener en cuenta la equidad, la transparencia y la responsabilidad en el diseño, implementación y aplicación de estas tecnologías para garantizar que se respeten los derechos y valores éticos fundamentales.

En términos sociales, la adopción de tecnologías de inspección automatizadas puede tener un impacto significativo en la fuerza laboral de la construcción, tanto en términos de capacitación y habilidades requeridas como en la redistribución de roles y responsabilidades. Además, es importante considerar cómo estas tecnologías pueden influir en la percepción pública de la seguridad y calidad de los edificios, así como en la confianza en las instituciones y profesionales del sector de la construcción.