



*remote sensing*

IMPACT  
FACTOR  
5.0

CITESCORE  
7.9

Article

---

# Multisensor Data Fusion by Means of Voxelization: Application to a Construction Element of Historic Heritage

---

Javier Raimundo, Serafin Lopez-Cuervo Medina, Julian Aguirre de Mata and Juan F. Prieto

Special Issue

[Advances in Remote Sensing for Exploring Ancient History](#)

Edited by

Dr. Nicola Masini, Prof. Dr. Apostolos Sarris and Dr. Rosa Lasaponara



<https://doi.org/10.3390/rs14174172>

Article

# Multisensor Data Fusion by Means of Voxelization: Application to a Construction Element of Historic Heritage

Javier Raimundo \* , Serafin Lopez-Cuervo Medina , Julian Aguirre de Mata  and Juan F. Prieto 

Departamento de Ingeniería Topográfica y Cartográfica, Escuela Técnica Superior de Ingenieros en Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, Campus Sur, A-3, Km 7, 28031 Madrid, Spain

\* Correspondence: ajaimundo@alumnos.upm.es

**Abstract:** Point clouds are very common tools used in the work of documenting historic heritage buildings. These clouds usually comprise millions of unrelated points and are not presented in an efficient data structure, making them complicated to use. Furthermore, point clouds do not contain topological or semantic information on the elements they represent. Added to these difficulties is the fact that a variety of different kinds of sensors and measurement methods are used in study and documentation work: photogrammetry, LIDAR, etc. Each point cloud must be fused and integrated so that decisions can be taken based on the total information supplied by all the sensors used. A system must be devised to represent the discrete set of points in order to organise, structure and fuse the point clouds. In this work we propose the concept of multispectral voxels to fuse the point clouds, thus integrating multisensor information in an efficient data structure, and applied it to the real case of a building element in an archaeological context. The use of multispectral voxels for the fusion of point clouds integrates all the multisensor information in their structure. This allows the use of very powerful algorithms such as automatic learning and machine learning to interpret the elements studied.



**Citation:** Raimundo, J.; Lopez-Cuervo Medina, S.; Aguirre de Mata, J.; Prieto, J.F. Multisensor Data Fusion by Means of Voxelization: Application to a Construction Element of Historic Heritage. *Remote Sens.* **2022**, *14*, 4172. <https://doi.org/10.3390/rs14174172>

Academic Editor: Nicola Masini

Received: 13 July 2022

Accepted: 17 August 2022

Published: 25 August 2022

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Keywords:** point cloud; voxel; voxelization; multispectral; multisensor


## 1. Introduction

Geometric data acquisition technologies are today an increasingly common tool in several fields such as remote sensing, construction, quality control, and the documentation and study of historic heritage. The use of both terrestrial (TLS) and aerial (ALS) laser scanners and techniques such as photogrammetry make possible to discretise the environment by means of a set of aggregated points which, taken as a whole, reproduce the shape of the object, building and/or terrain.

However, one drawback is that the use of 3D point clouds requires processing vast amounts of information. The Table 1 shows an example of the typical structure of a point cloud, which can only be processed and visualised with the aid of major data-processing infrastructures. Point clouds are also destructured, so there is a substantial problem locating specific points in these clouds [1]. Another consequence of the lack of structure in this type of data is that point clouds do not contain topological information, therefore making it impossible to determine the neighbourhood relations between the points [2].

Non-homogeneous densities are present in the registration of the point clouds, and the point density obtained is not always adequate for the intended application. Although a data collection campaign is designed with a minimum necessary geometric resolution (for example 5 points/dm<sup>2</sup>), this is only the minimum. For instance, in the case of mobile laser scanners (MLS), the geometric resolution will be determined by the density parameter chosen in the laser scanning equipment. Moreover, there will be zones with redundant information, particularly in the overlapping area between takes, while other zones will have lower point densities, even though the minimum resolution is guaranteed. This means

that the point density and precision are heterogeneous within the cloud [1]. Other factors to consider are added noise and points from objects outside the study (Figure 1).



**Figure 1.** Challenges in raw point clouds acquired from laser scanning and stereo vision (i.e., photogrammetry). (Source: Xu et al. (2021). [1]).

Point clouds are usually too dense and extensive for utilities such as rendering. Point clouds of more than 10 million points become impractical for classical visualisation algorithms [3]. Data structures must therefore be designed to allow the efficient and effective management of the information contained in the 3D point clouds.

The methods for assessing geometric information (3D coordinates) include alternatives to point clouds such as depth maps, tree models, and meshing and the use of voxels [1].

Voxels are the minimum abstract units in 3D, with predefined volumes, positions and attributes. Their name derives from the term “volumetric element” [4]. Voxels are extremely useful for representing point clouds in a topologically explicit way, thereby enriching the information. Due to their structure, they are very efficient to process and classify by means of 3D convolutional neural networks [2].

Previous research works on the analysis of point clouds using voxels describe the extraction of vegetation parameters in forest stands [5–7], studies on structures in historic heritage buildings [8], and the automatic extraction of buildings from point clouds by aerial laser scanner [9].

**Table 1.** Typical structure of a point cloud (example).

X (m)	Coordinates			Colour Information		
	Y (m)	Z (m)	I	R	G	B
532,238.001	4,274,986.273	5.923	−1319	29	22	16
532,238.342	4,274,986.295	5.910	−1252	36	27	20
532,238.348	4,274,986.297	5.912	−1359	40	27	19
[...]						
532,238.432	42,749,867.987	5.922	−1342	25	18	12

So far we have analysed the weaknesses and strengths of point clouds as data structures. However if we want to analyse several clouds from different sensors the problem arises of how to process all this information as a whole.

Previous research has been done into multisensor point clouds—that is to say, point clouds obtained with different sensors whose registered fields are unrelated with geometry—representing information from different parts of the electromagnetic spectrum. The first approaches were conducted with the aid of airborne laser scanners (ALS), using laser beams with different wavelengths in the same take [10]. In subsequent works methodologies were

designed to extract entities from these multispectral points in airborne laser sensors [11] with the aid of specific instruments that contribute multispectrality in a single point cloud.

Other authors have used voxels for the fusion of different types of data:

- Fusion of medical data from imaging techniques [12] and magnetic resonance image (MRI) data [13,14].
- Geological data from different sources [15].
- LIDAR data with RADAR data [16,17].
- LIDAR point clouds with images [18,19].
- Stereo-LIDAR fusion [20].
- Terrestrial laser scanner (TLS) with hyperspectral images [21].
- Texture Mapping and 3-D Scene-data Fusion with Radioactive Source [22].

No method has been developed to date for the integrated fusion of data from diverse origins in a voxelized structure.

We therefore present a method to fuse data from different origins, specifically multi-sensor data represented by point clouds. This method uses voxelization to improve and resolve the difficulties inherent in the individual processing of point clouds by combining them in a more powerful and effective structure. This enables their joint analysis, with all the available information regardless of the amount or number of different sensors involved, in an effective and efficient way.

After this introduction we outline the most commonly used technologies for acquiring point clouds, and the data collection carried out to test our methodology. We define the concept of multispectral voxel to combine heterogeneous information from different sensors and/or different takes in an efficient data structure for subsequent processes. The results obtained are then analysed, followed by a discussion of the use of voxels for the fusion of multisensor data.

## 2. Materials and Methods

The most widely used geometric data acquisition technologies today are laser scanner and photogrammetry. These data can also be captured by means of depth sensors or deep learning algorithms through generative adversarial networks [23]. Although these are all different techniques, the final product is similar: point clouds defined by their cartesian coordinates in space (XYZ), along with additional registered properties (see Table 1).

Laser scanners function by means of the emission and return of an electromagnetic wave, and register the intensity of the return of this beam. They can sometimes also record information on the colour of the point if they have support from some visible spectrum sensor (camera) [24].


The outputs of photogrammetry are point clouds from homologous entities identified in photographs taken with digital image sensors. The information accompanying the point geometry will depend on the type of sensor and the part of the electromagnetic spectrum to which it is sensitive, registered by a digital value that usually corresponds to its colour. Using visible spectrum cameras (conventional cameras), colour is obtained in its green, red and blue components (bands). However, if multispectral, thermographic, ultraviolet, etc., cameras are used, the information registered will correspond to the part of the spectrum to which each sensor is sensitive [25]. Previous research work has been done in the field of fusing infrared thermal data with visible spectrum images. The product of this infrared-visible fusion is a thermal infrared point cloud with higher resolution than could be obtained from the original thermal sensor [26].

In addition to the problems of data structure, heterogeneity, variable density etc. described above, multisensor point clouds will have a different data source and express different information. It is necessary to devise techniques to fuse both the geometric and spectral information in order to facilitate processing and obtain conclusions from the different information they contain.

### 2.1. Data Collection

In order to demonstrate the potential of the use of voxels for processing multisensor point clouds, a building element from a site containing a historic enclosure wall was registered with a variety of sensors.

The element is located in the town of Humanes de Madrid (Madrid, Spain), with geographic coordinates 40.250177°N, 3.828382°W. In Figure 2 its geographic location in Spain is shown, as well as a photograph of the wall itself (Figure 3). The dimensions of the chosen wall are approximately 20 × 3 m.



**Figure 2.** Location of the study object in Spain.



**Figure 3.** The historic wall object of the field study.

The selection of this site and this historical architectural element is justified by the fact that in ancient history research works the main elements to be studied are walls. The

fusion of point clouds by voxelization does not depend on the geometry (shape) of the element. The fusion can be done by elements or by the whole building or environment to be studied as a whole. The point cloud selected as the starting point for defining the voxelised structure will determine the limits of the study area in each case.

The data were collected by means of photogrammetric techniques, with several sensors. A series of photogrammetric data acquisition missions were designed to obtain different point clouds of the same object. Thus, each point cloud, while representing the geometric reality of this historic architectural element, adds the intrinsic spectral information of the sensor used, or of the filter used in that capture. These data acquisition sessions were carried out sequentially to ensure that the environmental conditions did not change significantly. Special care was taken in the design of the data collection missions to ensure that the weather and environmental conditions did not vary. When taking the photographs, no part of the wall was directly illuminated by the sun, which would cause discrepancies in the values acquired. Other variables such as humidity and wind remained constant throughout the acquisition time. Two different cameras, equipping several filters depending on desired spectral information, were used in this work:

- Sony digital image camera model Nex-7, with a 19 mm fixed-length optical lens. This sensor records the spectral components corresponding to the red (590 nm), green (520 nm) and blue (460 nm) bands. In Table 2 we show these used sensor parameters.
- Modified digital image camera model Sony Nex-5N (Table 3), equipped with a 16 mm fixed-length lens, with near infrared filter and an ultraviolet filter.

**Table 2.** Sony NEX 7 camera sensor parameters.


Parameter	Value
Sensor	APS-C type CMOS sensor
Focal length (mm)	19
Sensor width (mm)	23.5
Sensor length (mm)	15.6
Effective pixels (megapixels)	24.3
Pixel size (microns)	3.92
ISO sensitivity range	100–1600
Image format	RAW (Sony ARW 2.3 format),
Weight (g)	350

**Table 3.** Sony NEX 5N camera sensor parameters.


Parameter	Value
Sensor	APS-C type CMOS sensor
Focal length (mm)	16
Sensor width (mm)	23.5
Sensor length (mm)	15.6
Effective pixels (megapixels)	16.7
Pixel size (microns)	4.82
ISO sensitivity range	100–3200
Image format	RAW (Sony ARW 2.2 format),
Weight (g)	269

Figure 4 shows the spectral response of the unmodified Sony NEX sensor. If we removed the internal infrared filter, this Sony sensor will become sensitive to parts of the electromagnetic spectrum such as the near infrared (820 nm) and the ultraviolet (390 nm). In Figure 5 we shows the spectral response of the modified Sony sensor [27]. Combined with different filters we can acquire different spectral information than the one we can achieve with the unmodified sensor. Figures 6 and 7 show the transmission curves of the these used filters during capture process.

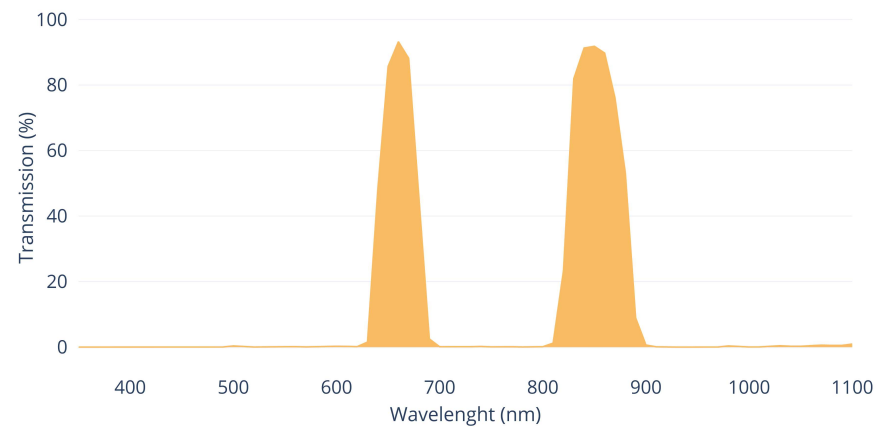
In this work, we have used consumer photographic cameras, one of them modified, to demonstrate that multispectral point clouds can be obtained with low-cost sensors.




**Figure 4.** Spectral response for the unmodified Sony camera, normalised to the peak of the green channel (Source: Berra et al. [27]).



**Figure 5.** Spectral response for the modified Sony camera, normalised to the peak of the red channel (Source: Berra et al. [27]).



**Figure 6.** Midopt DB 660/850 Dual Bandpass filter light transmission curve (Source: Midwest Optical Systems, Inc.).



**Figure 7.** ZB2 filter light transmission curve. (Source: Shijiazhuang Tangsinuo Optoelectronic Technology Co., Ltd.).

The use in this work of only two different photogrammetric sensors for point cloud fusion does not imply that the voxelization fusion process can only be used with point clouds originated from this technique. As mentioned in the introduction, there are several tools and methods for obtaining point clouds, nowadays making great advances in this research field. Each sensor involved, apart from the geometrical data, provides different information inherent to its characteristics or the methodology used in the data acquisition. Our research is independent of the number of sensors used or their technology. In this case, we are going to fuse five point clouds by voxelization, analysing their advantages and limitations.

The process of image capture for subsequent photogrammetric processing was designed in such a way that the individual images were taken at a distance of approximately 3 m from the wall. The distance could not be greater due to the narrowness of the street where this historic location is situated. The overlap was always greater than 90% between consecutive images and two passes were made, each with a different camera orientation, with each sensor and filter combination.

Figures 8–10 show examples of the images obtained with each sensor and filter combination. Figure 8 shows an image taken by the unmodified Sony Nex7 visible spectrum camera with no additional filter. Figure 9 corresponds to the modified Sony Nex5N camera mounting a Midopt DB 660/850 Dual Bandpass filter. Finally, in Figure 10 we show a detail of the image corresponding to the modified camera mounting a ZB2 ultraviolet filter.



**Figure 8.** Photograph taken by visible spectrum camera.



**Figure 9.** Photograph by modified camera mounting NIR/blue dualband pass filter.



**Figure 10.** Picture of the wall with modified camera and ZB2 ultraviolet filter.

Before taking the photographs, a series of precision targets were marked on the wall and their interdistances were measured with a fibreglass measuring tape with centimetre precision. These marks define a set of control points and a common geometric reference system for all the takes (Figure 11).

The set of photographs in the visible spectrum consists of 398 images, the near-infrared set consists of 340 images, and the ultraviolet group of images comprises 309 photographs.


The photographs from the different sensors were processed with the photogrammetric processing application Agisoft Metashape version 1.6.1 build 10,009 (64 bits). Figures 12 and 13 show the distribution of shots for the visible spectrum point cloud.

The precision targets were identified in all the photographs (Figure 14) in a way that defined a local reference system, in which all the different point clouds were integrated. Thus, we have several point clouds in a common reference system. In this particular case, we did not consider georeferencing these targets, as we intend to demonstrate the feasibility of the fusion of point clouds by voxelization. We consider that georeferencing of point clouds should be carried out in any case where the precise marking can not be permanent, which is common in the context of ancient history buildings. This georeferencing process will help a lot in the event that new data acquisition has to be realised.

The result of the photogrammetric process of the visible spectrum capture was a point cloud whose RGB colour property corresponds to the spectral information in the red, green and blue bands. On the other hand, the point clouds of the near infrared and ultraviolet set, although the points present the colour fields structure, the same as the visible spectrum point cloud, only the information corresponding to the desired spectral information has been taken. For the near-infrared cloud, the information of the field corresponding to “red” was taken, while for the cloud of points coming from the process with the ultraviolet images set, only the colour property corresponding to “blue” field was used.




**Figure 11.** Example of the precision marks used.




**Figure 12.** Distribution of the shots taken during visible spectrum capture process (front view).

Five different point clouds were obtained as a final output of this data processing phase, corresponding to different spectral bands: red, green, blue, infrared and ultraviolet. To clarify, the geometry of the visible spectral point cloud, as all the points positions coincide because they come from the same cloud, has been split into three different ones

because they contain distinct spectral information, in single bands, such as the infrared and ultraviolet point clouds.



**Figure 13.** Distribution of the shots taken during visible spectrum capture process (upper view).



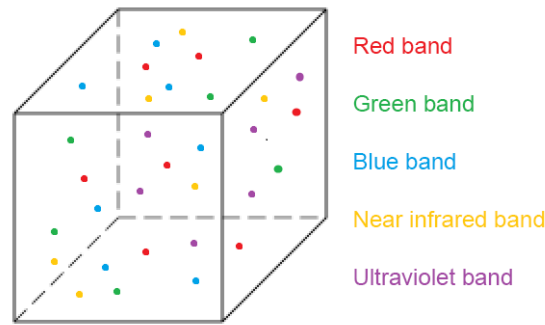
**Figure 14.** Diagram with the location of all precision targets on the studied historic wall (NIR point cloud).

## 2.2. Fusion of Point Clouds by Voxelization

We now have several point clouds (five, in this particular study) in a common reference system, but with different information. To be able to merge these point clouds and subsequently analyse the information provided by each one in an integrated way, we propose the concept of multispectral voxel. A multispectral voxel is defined not only by its size and position, but by the characteristics of the points it contains (Figure 15).

When processing point clouds in their voxelization, one of the parameters that defines the structure of voxels is the size of the elemental voxel. This parameter will determine the resolution of the phenomena to be studied thanks to the data structure (finite elements [8], structural studies [28,29], dynamic phenomena [30], etc.). For example, if the study or simulation requires a resolution of 5 cm, this will be the voxel size to be set in the voxelization process. The size of the voxel will also establish the degree of reduction of the elements compared to the number of points in the original clouds.

The voxelization process consists of dividing the point cloud into unique elements defined by tetrahedrons (although other geometric figures can be defined such as spheres, cylinders, etc.), all with a single uniform size. We first determine the defining framework (bounding box) with the limits of the point cloud on each of the three axes XYZ. In this first step of the voxelization, one of the point clouds representing the study object is taken as a reference. The number of voxels in each direction is obtained by dividing the dimensions of the bounding box by the dimension of the elemental voxel selected [31]. This voxelization process is included in the Open3D open code library [32].



**Figure 15.** Definition of a multispectral voxel.

Once the voxelized data structure has been defined, the data can be fused. Each voxel is defined by its centroid, with its geometric coordinates  $XYZ$ , and by its contour. We locate the centroid nearest to each point in the cloud, which is then assigned to the voxel represented by this centroid. The centroid closest to each point can be searched using the closest-pair or KDTree algorithms [33].

As the whole cloud has been covered, we will have identified the points that are contained within each voxel. The property transmitted by the points to the voxel containing them will be the mean of the values of the points in each individual spectral band. In other words, if a voxel contains many points of the same point cloud, the corresponding spectral information value of that voxel will be the mean of the spectral values of the points contained in it. Other statistical measurements can be calculated in addition to the mean, such as the maximum and minimum values, variance, skewness and kurtosis, which will give a measure of the dispersion and variability of the spectral information transmitted by these contained points. This process is then repeated for each point cloud to be fused.

Figure 16 shows the methodology designed for the fusion of point clouds from heterogeneous sensors by voxelization. The final output is a series of voxels integrating the multispectral information contained in them. Given the heterogeneity of the point density, there may be voxels that do not include points from any of the different clouds. A complete voxel is considered to be one that contains at least one point from all the point clouds analysed. Incomplete voxels must be identified in order to handle them correctly in subsequent processes.

The voxelization was done based on the cloud from the visible spectrum photographs taken with the unmodified camera. This is because, in this particular case, it is the largest point cloud. This does not imply that none of the other point clouds can be used as a starting point for defining the voxelized structure. This original visible point cloud has over 39 million points (RGB point cloud). The Table 4 shows the number of voxels obtained by varying their size in regard to the original point cloud. Voxel size multiples such as  $\times 2$ ,  $\times 5$ ,  $\times 10$ , etc. have been chosen. As can be seen, varying the voxel size by half does not imply half the number of voxels are obtained, and vice versa.

**Table 4.** Number of voxels relative to their size.

Voxel Size (cm)	Number of Voxels
0.5	4,621,255
1	1,193,994
5	46,532
10	11,292
15	4984
20	2658
30	1281
50	461

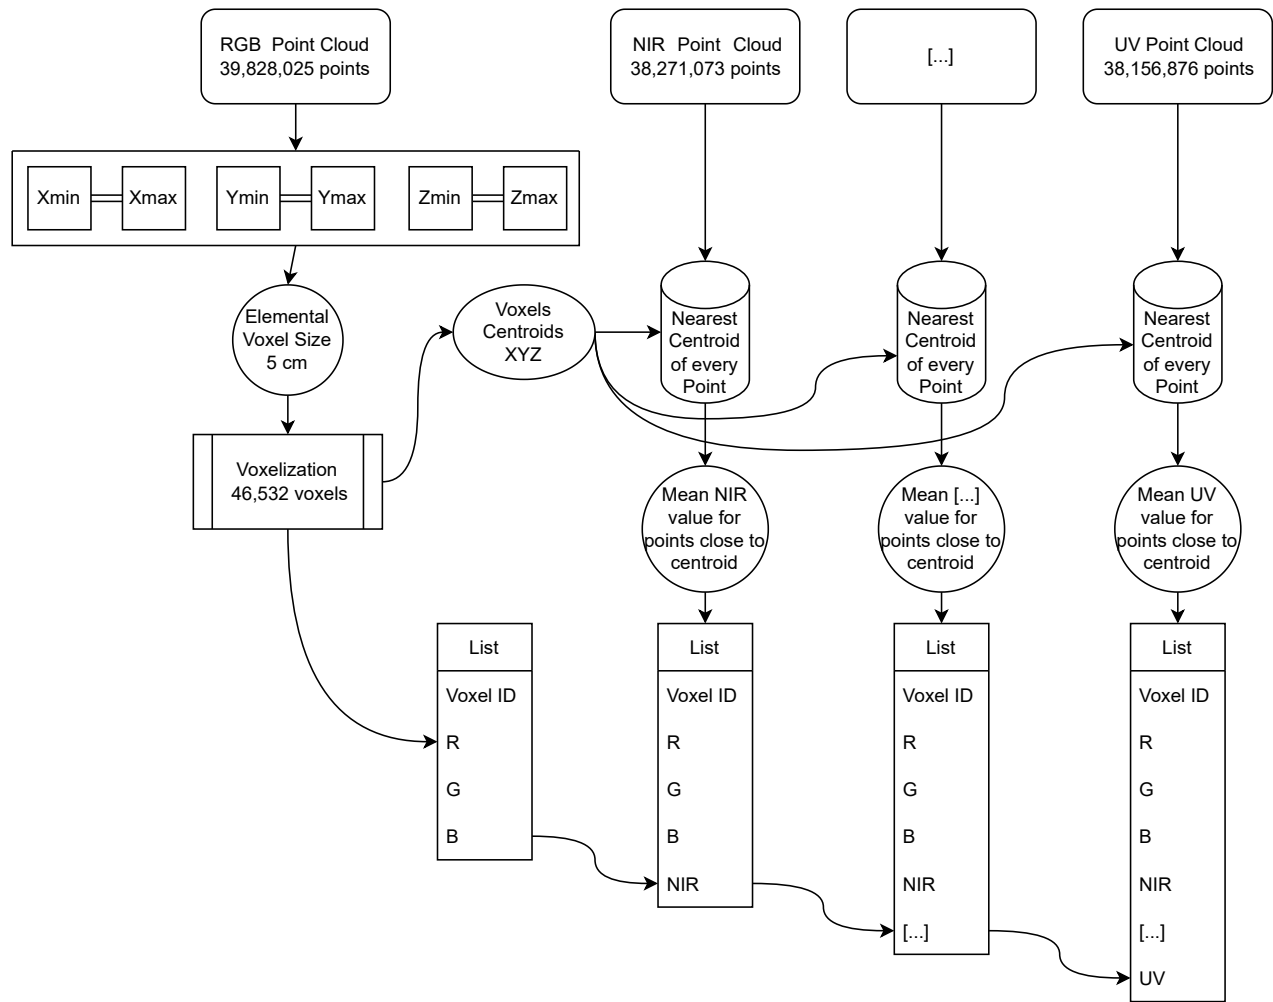


Figure 16. Point clouds voxelization fusion flowchart.

Figures 17–19 show the voxelizations obtained at voxel size resolutions of 50, 15 and 0.5 cm, as an example.

The size of the set of elements to be analysed in subsequent processes has been drastically reduced. It is no longer necessary to store millions of points; by performing the voxelization, the geometry of the construction element is contained in a much smaller set of voxels. In this study case, the original RGB cloud has 39,828,025 points, and the number of elements resulting in the case of voxel resolutions of 0.5 cm is 11.60%. At a resolution of 1 cm, the voxels are 2.99% compared to the original.




Figure 17. Voxelization with a voxel size of 50 cm.



**Figure 18.** Voxelization with a voxel size of 15 cm.



**Figure 19.** Voxelization with a voxel size of 0.5 cm.

### 3. Discussion

Up to this point, we have the multispectral voxel structure containing the geometry and the spectral information of the whole used multisensor set. We first analyse the size in memory of the new data structure generated by these multispectral voxels. The Table 5 shows the size of the point clouds analysed. In addition to the geometry, the RGB point cloud contains the spectral information on the red, green and blue bands, since its points provide this colour information. In the rest of the point clouds the points contain the information corresponding to a single band (NIR and UV in each case). Each point in the cloud is defined by its three XYZ coordinates plus its colour attribute (Table 1). This means that in the case of the minimum information necessary, each point must be declared by the four variables X, Y, Z + spectral information (“colour”), all represented by values in double precision. Each point is four elements  $\times$  8 bytes = 32 bytes. Given that the geometric description of the construction elements to be studied in architecture, engineering and archeology rarely comprises fewer than several million points, even the simplest element will require a large amount of memory to process. However, voxelization reduces the memory size necessary for optimum handling and analysis. In our work case, the voxelized geometry uses 7.48% memory with a voxel size of 5 mm, compared to the combined size of the three clouds (Table 5).

**Table 5.** Variation of point cloud size in memory with respect to voxelization.

Point Cloud	Number of Elements	Memory Space Needed (Mbytes)
RGB <sup>1</sup>	39,828,025	1911.75
NIR	38,271,073	1224.67
UV	25,115,133	803.68
<b>Total</b>	<b>103,214,231</b>	<b>3940.10</b>
Voxel (0.5 cm size)	4,621,255	295.76

<sup>1</sup> RGB point cloud comprises the spectral information for red, green and blue bands.

The geometric resolution in the study object is now homogeneous, and there are no areas with a lower point density than others. Once the resolution of the voxel has been established, any possible redundancy of information is eliminated in the areas with a greater point density. The voxelization concept ensures that all elements are equal in their geometric resolution. This means that they are perfectly located and do not overlap each

other, avoiding redundancies and storage of useless information. The option of establishing the working resolution means it is possible to work only with the information relevant to the phenomenon to be studied.

Regarding multispectral voxel properties, voxels have topological properties such as neighbourhood. Each voxel is identified by three indices ( $V_{i,j,k}$ ) on each of the three Cartesian axes in the space. Given a particular voxel, it is simple to find the adjacent voxels with which to semantically classify the object or parts of the object.

The voxels defined as complete present all the information possible on the clouds integrated in them. Incomplete voxels can be located in order to determine what information needs to be added in subsequent takes, and the additional points can then be processed again so that all the voxels are complete (in terms of their radiometric information).

All of the above therefore confirms that, in addition to producing a highly significant reduction in the number of elements to be analysed, the use of voxels for the fusion of point clouds offers a series of very interesting and necessary properties for the subsequent analysis and interpretation of the results. Our methodology is independent of the number and type of sensors used to obtain the point clouds and defines a highly efficient data structure that integrates all the radiometric information in its interior.

#### 4. Conclusions

The large volume of data supplied by data acquisition technologies through point clouds allows a detailed analysis of the objects to be studied. However, this massive amount of data raises the problem of how to process them, which may be impossible in the cases researchers lack the necessary infrastructure for their handling and visualisation. Solutions are required to overcome this challenge in the field of information generation and management, particularly if the aim is to merge heterogeneous information. This work proposes the concept of multispectral voxels for the fusion of point clouds from different sensors. We have tested our methodology, demonstrating the potential of using voxels for the study, processing and fusion of point clouds from multiple sensors, in a real case, as it can be presented to researchers in the field.

We identify the advantages of using the voxelization method to fuse point clouds, and quantify the reduction in the size of the information allowed by this technique. Although, on certain occasions, geometric description of archaeological elements may be lost due to the choice of a too large voxel size, the fusion of multisensor point clouds by voxelization integrates in its structure all the information of the original point clouds without loss, giving it an optimal data structure for processing and study.

In addition to the described problems presented by the use of raw point clouds, this work presents voxelization for the fusion of multisensor point clouds as a solution that provides a new tool in the study of ancient history elements from a new perspective. It is no longer necessary to perform the analysis for each point cloud for each technology and spectral information obtained, but from a global and integrated point of view. Multispectral voxels, in addition to all the advantages they present as a data structure, allow us to obtain conclusions that would have been impossible with single analyses, as synergies appear through the multispectral information contained in them.

In future lines of work the aim is to combine point clouds from different origins: photogrammetry, laser scanner, terrestrial and aerial sensors and additional parts of the electromagnetic spectrum such as microwaves and thermal infrared, in order to study the pathologies present in buildings, particularly ancient history buildings, with machine learning algorithms. Although there is research that has already used point clouds for the study of pathology in historic buildings based on point clouds [34], it only analyses one point cloud at a time, without integrating the information that could be obtained from other methods. This means that their individual analyses cannot be integrated together. The potential of the method we have described here will help to integrate the information from all these sensors in such a way that by combining the information from all of them, it will be possible to identify the pathological areas of historical heritage buildings in a

manageable structure. Multispectral voxels will be used as the keystone for automatic detection and classification algorithms.

Our work in using multispectral voxels for multisensor point cloud fusion will lead the study of these algorithms to a very significant advance due to the properties they present.

**Author Contributions:** All authors have made significant contributions to this manuscript. Conceptualization, J.R., S.L.-C.M. and J.F.P.; methodology, J.R.; software, J.R.; validation, J.R.; formal analysis, J.R., S.L.-C.M. and J.F.P.; investigation, J.R.; field observations: J.R.; resources, J.R., S.L.-C.M. and J.F.P.; data curation, J.R. and S.L.-C.M.; writing—original draft preparation, J.R.; writing—review and editing, J.R., S.L.-C.M., J.A.d.M. and J.F.P.; supervision, S.L.-C.M., J.A.d.M. and J.F.P. All authors have read and agreed to the published version of the manuscript.

**Funding:** The work from S.L.-C.M., J.A.d.M. and J.F.P. has been partially supported by the Spanish Ministerio de Ciencia, Innovación y Universidades research project DEEP-MAPS (RTI2018-093874-B-I00) and the CAM research project LABPA-CM (H2019/HUM-5692). Furthermore, S.L.-C.M. has been supported by National Research Project PCD1912570307 AUDECA: Control de la vegetación en Conservación Integral de Carreteras mediante la fusión de información con sensores multi-hiperespectrales and National Research Project PCD1912570308 ALVAC: Control de la vegetación en Conservación Integral de Carreteras mediante la fusión de información con sensores multi hiperespectrales.

**Data Availability Statement:** Not applicable.

**Acknowledgments:** We would like to acknowledge Pru Brooke-Turner (M.A. Cantab.) for her English language and style review of the original manuscript. We also want to thank the staff of the Geovisualización, Espacios Singulares y Patrimonio (GESyP) research group for their dedicated work and support. The first author, Javier Raimundo, would also like to thank the Consejo General de la Arquitectura Técnica de España (CGATE) for their support.

**Conflicts of Interest:** The authors declare no conflict of interest.

## Abbreviations

The following abbreviations are used in this manuscript:

TLS	Terrestrial Laser Scanning
MLS	Mobile Laser Scanning
ALS	Aerial Laser Scanning
MRI	Magnetic Resonance Imaging
LIDAR	Light Detection and Ranging
RADAR	Radio Detection and Ranging
GAN	Generative Adversarial Networks

## References

- Xu, Y.; Tong, X.; Stilla, U. Voxel-based representation of 3D point clouds: Methods, applications, and its potential use in the construction industry. *Autom. Constr.* **2021**, *126*, 103675. [\[CrossRef\]](#)
- Poux, F.; Billen, R. Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods. *ISPRS Int. J. Geo-Inf.* **2019**, *8*, 213. [\[CrossRef\]](#)
- Poux, F.; Neuville, R.; Van Wersch, L.; Nys, G.A.; Billen, R. 3D point clouds in archaeology: Advances in acquisition, processing and knowledge integration applied to quasi-planar objects. *Geosciences* **2017**, *7*, 96. [\[CrossRef\]](#)
- Foley, J.D. *Computer Graphics: Principles and Practice*; Addison Wesley: Reading, UK, 1990.
- Okhrimenko, M.; Coburn, C.; Hopkinson, C. Multi-spectral lidar: Radiometric calibration, canopy spectral reflectance, and vegetation vertical SVI profiles. *Remote Sens.* **2019**, *11*, 1556. [\[CrossRef\]](#)
- Goodbody, T.R.; Tompalski, P.; Coops, N.C.; Hopkinson, C.; Treitz, P.; van Ewijk, K. Forest Inventory and Diversity Attribute Modelling Using Structural and Intensity Metrics from Multi-Spectral Airborne Laser Scanning Data. *Remote Sens.* **2020**, *12*, 2109. [\[CrossRef\]](#)
- Jurado, J.M.; Ortega, L.; Cubillas, J.J.; Feito, F.R. Multispectral Mapping on 3D Models and Multi-Temporal Monitoring for Individual Characterization of Olive Trees. *Remote Sens.* **2020**, *12*, 1106. [\[CrossRef\]](#)
- Castellazzi, G.; D'Altri, A.; Bitelli, G.; Selvaggi, I.; Lambertini, A. From Laser Scanning to Finite Element Analysis of Complex Buildings by Using a Semi-Automatic Procedure. *Sensors* **2015**, *15*, 18360–18380. [\[CrossRef\]](#)
- Li, D.; Shen, X.; Yu, Y.; Guan, H.; Li, J.; Zhang, G.; Li, D. Building Extraction from Airborne Multi-Spectral LiDAR Point Clouds Based on Graph Geometric Moments Convolutional Neural Networks. *Remote Sens.* **2020**, *12*, 3186. [\[CrossRef\]](#)

10. Zhou, Z.; Gong, J.; Guo, M. Image-Based 3D Reconstruction for Posthurricane Residential Building Damage Assessment. *J. Comput. Civ. Eng.* **2016**, *30*, 04015015. [[CrossRef](#)]
11. Dai, W.; Yang, B.; Dong, Z.; Shaker, A. A new method for 3D individual tree extraction using multispectral airborne LiDAR point clouds. *ISPRS J. Photogramm. Remote Sens.* **2018**, *144*, 400–411. [[CrossRef](#)]
12. Xie, H.; Li, G.; Ning, H.; Ménard, C.; Colemah, C.N.; Miller, R.W. 3D voxel fusion of multi-modality medical images in a clinical treatment planning system. *IEEE Symp. Comput.-Based Med. Syst.* **2004**, *17*, 48–53. [[CrossRef](#)]
13. Sun, L.; Zu, C.; Shao, W.; Guang, J.; Zhang, D.; Liu, M. Reliability-based robust multi-atlas label fusion for brain MRI segmentation. *Artif. Intell. Med.* **2019**, *96*, 12–24. [[CrossRef](#)] [[PubMed](#)]
14. Zhang, L.; Wang, L.; Gao, J.; Risacher, S.L.; Yan, J.; Li, G.; Liu, T.; Zhu, D. Deep Fusion of Brain Structure-Function in Mild Cognitive Impairment. *Med. Image Anal.* **2021**, *72*, 102082. [[CrossRef](#)]
15. Li, J.; Liu, P.R.; Liang, Z.X.; Wang, X.Y.; Wang, G.Y. Three-dimensional geological modeling method of regular voxel splitting based on multi-source data fusion. *Yantu Lixue Rock Soil Mech.* **2021**, *42*, 1170–1177. [[CrossRef](#)]
16. Yang, B.; Guo, R.; Liang, M.; Casas, S.; Urtasun, R. RadarNet: Exploiting Radar for Robust Perception of Dynamic Objects. *arXiv* **2020**, arXiv:2007.14366.
17. Nobis, F.; Shafiei, E.; Karle, P.; Betz, J.; Lienkamp, M. Radar Voxel Fusion for 3D Object Detection. *Appl. Sci.* **2021**, *11*, 5598. [[CrossRef](#)]
18. Li, Y.; Xie, H.; Shin, H. 3D Object Detection Using Frustums and Attention Modules for Images and Point Clouds. *Signals* **2021**, *2*, 98–107. [[CrossRef](#)]
19. Wang, N.; Sun, P. Multi-fusion with attention mechanism for 3D object detection. *Int. Conf. Softw. Eng. Knowl. Eng. SEKE* **2021**, *2021*, 475–480. [[CrossRef](#)]
20. Choe, J.; Joo, K.; Imtiaz, T.; Kweon, I.S. Volumetric Propagation Network: Stereo-LiDAR Fusion for Long-Range Depth Estimation. *IEEE Robot. Autom. Lett.* **2021**, *6*, 4672–4679. [[CrossRef](#)]
21. Schulze-Brüninghoff, D.; Wachendorf, M.; Astor, T. Remote sensing data fusion as a tool for biomass prediction in extensive grasslands invaded by *L. polyphyllus*. *Remote Sens. Ecol. Conserv.* **2021**, *7*, 198–213. [[CrossRef](#)]
22. Yang, C.; Li, Y.; Wei, M.; Wen, J. Voxel-Based Texture Mapping and 3-D Scene-data Fusion with Radioactive Source. In Proceedings of the 2020 The 8th International Conference on Information Technology: IoT and Smart City, Xi'an, China, 25–27 December 2020; ACM: New York, NY, USA, 2020; pp. 105–109. [[CrossRef](#)]
23. Wang, X.; Xu, D.; Gu, F. 3D model inpainting based on 3D deep convolutional generative adversarial network. *IEEE Access* **2020**, *8*, 170355–170363. [[CrossRef](#)]
24. Al-Manasir, K.; Fraser, C.S. Registration of terrestrial laser scanner data using imagery. *Photogramm. Rec.* **2006**, *21*, 255–268. [[CrossRef](#)]
25. Hedeard, S.B.; Brøns, C.; Drug, I.; Saulins, P.; Bercu, C.; Jakovlev, A.; Kjær, L. Multispectral photogrammetry: 3D models highlighting traces of paint on ancient sculptures. *CEUR Workshop Proc.* **2019**, *2364*, 181–189.
26. Raimundo, J.; Medina, S.L.C.; Prieto, J.F.; de Mata, J.A. Super resolution infrared thermal imaging using pansharpening algorithms: Quantitative assessment and application to uav thermal imaging. *Sensors* **2021**, *21*, 1265. [[CrossRef](#)] [[PubMed](#)]
27. Berra, E.; Gibson-Poole, S.; MacArthur, A.; Gaulton, R.; Hamilton, A. Estimation of the spectral sensitivity functions of unmodified and modified commercial off-the-shelf digital cameras to enable their use as a multispectral imaging system for UAVs. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2015**, *40*, 207–214. [[CrossRef](#)]
28. Bitelli, G.; Castellazzi, G.; D'Altri, A.; De Miranda, S.; Lambertini, A.; Selvaggi, I. Automated Voxel model from point clouds for structural analysis of Cultural Heritage. *ISPRS Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2016**, *XLI-B5*, 191–197. [[CrossRef](#)]
29. Zhang, C.; Jamshidi, M.; Chang, C.C.; Liang, X.; Chen, Z.; Gui, W. Concrete Crack Quantification using Voxel-Based Reconstruction and Bayesian Data Fusion. *IEEE Trans. Ind. Inform.* **2022**, *1*. [[CrossRef](#)]
30. Wang, Y.; Xiao, Y.; Xiong, F.; Jiang, W.; Cao, Z.; Zhou, J.T.; Yuan, J. 3DV: 3D dynamic voxel for action recognition in depth video. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 13–19 June 2020; pp. 508–517. [[CrossRef](#)]
31. Poux, F.; Neuville, R.; Nys, G.A.; Billen, R. 3D point cloud semantic modelling: Integrated framework for indoor spaces and furniture. *Remote Sens.* **2018**, *10*, 1412. [[CrossRef](#)]
32. Zhou, Q.Y.; Park, J.; Koltun, V. Open3D: A Modern Library for 3D Data Processing. *arXiv* **2018**, arXiv:1801.09847.
33. Shi, G.; Gao, X.; Dang, X. Improved ICP point cloud registration based on KDTree. *Int. J. Earth Sci. Eng.* **2016**, *9*, 2195–2199.
34. Musicco, A.; Galantucci, R.A.; Bruno, S.; Verdoscia, C.; Fatiguso, F. Automatic Point Cloud Segmentation for the Detection of Alterations on Historical Buildings Through an Unsupervised and Clustering-Based Machine Learning Approach. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2021**, *V-2-2021*, 129–136. [[CrossRef](#)]

## Capítulo 5

# Fusión avanzada de datos multisensor con aprendizaje profundo para la evaluación de edificios

*When you can measure what you are speaking about, and express it in numbers, you know something about it; but when you cannot measure it, when you cannot express it in numbers, your knowledge is of a meagre and unsatisfactory kind: it may be the beginning of knowledge, but you have scarcely, in your thoughts, advanced to the stage of science, whatever the matter may be.*

Cuando puedes medir aquello de lo que estás hablando y expresarlo en números sabes algo sobre ello; pero cuando no puedes medirlo, cuando no puedes expresarlo en números, tu conocimiento es de un tipo pobre e insatisfactorio. Puede ser el principio del conocimiento, pero apenas has avanzado, en tu pensamiento, hasta el estadio de la ciencia, sea cual sea el asunto.

---

*Electrical Units of Measurement.*

WILLIAM THOMPSON, LORD KELVIN (1883)

La tarea de preservar, conservar y restaurar monumentos y edificaciones de valor histórico demanda una meticulosa documentación en tres dimensiones y un análisis diagnóstico, siendo comúnmente asignadas a equipos de naturaleza interdisciplinaria [107]. Dichas actividades generan un extenso espectro de información diversa, abarcando desde restituciones en 2D, datos geométricos en 3D y hasta esbozos elaborados directamente en el terreno, documentos textuales e imágenes tanto en el espectro visible, térmico, infrarrojo, etc. La tarea de amalgamar esta

información heterogénea en un solo modelo informativo que apoye eficazmente las operaciones de conservación sigue representando un desafío no resuelto dentro del campo de las ciencias enfocadas al Patrimonio Histórico [90, 52, 1, 79]. En lo que respecta exclusivamente a los datos tridimensionales, su manipulación, interpretación y representación visual suelen ser procesos que demandan un considerable lapso de tiempo y requisitos técnicos exigentes en cuanto a las especificaciones del hardware. En el contexto del Patrimonio Digital, cobra especial relevancia el desarrollo de metodologías adaptadas para gestionar de manera eficiente, rápida, segura y accesible los datos 3D, especialmente para mejorar la comprensión y accesibilidad por parte de los usuarios, un avance imperativo que permitirá a los especialistas en patrimonio explotar en su totalidad la riqueza informativa (geométrica, de texturas y semántica) contenida en estos datos [18].

Hoy día, un volumen significativo de los datos en el ámbito del Patrimonio Cultural se registra en forma de nubes de puntos, como mencionamos en el capítulo 4. Estos datos requieren un procesamiento especializado para convertirlos de una forma geométrica bruta a información significativa y de mayor utilidad. La segmentación de estas nubes de puntos en categorías semánticamente ricas, ajustadas a las especificidades de cada escena y proyecto, constituye el proceso de enriquecimiento semántico del patrimonio. Para la clasificación del patrimonio en 3D se han ideado numerosas técnicas, predominando los entrenamientos supervisados [85, 35, 70, 108, 62, 36, 68, 63], mientras que los entrenamientos no supervisados aún se encuentran en etapas iniciales de desarrollo. Esta situación pone de manifiesto la urgencia de promover el progreso en la investigación y el desarrollo de estrategias que permitan un aprovechamiento más amplio y profundo de los complejos conjuntos de datos tridimensionales en el dominio del patrimonio cultural, resaltando la necesidad de innovación tanto metodológica como tecnológica en este campo.

## 5.1 Problemas y desafíos

La investigación y estudio de patologías en edificios, especialmente en el contexto de la fusión de datos de diferentes sensores geomáticos, enfrenta varios desafíos importantes. Estos problemas derivan tanto de la complejidad técnica de integrar datos heterogéneos como de las limitaciones inherentes a los métodos de análisis y procesamiento de datos. Aquí resumimos varias de las áreas problemáticas comunes en este tipo de investigaciones, algunas de ellas ya mencionadas en el capítulo 4:

1. Heterogeneidad de datos.

Los distintos sensores geomáticos capturan datos en diversos formatos, resoluciones y rangos espectrales. La integración de estos datos heterogéneos en un modelo coherente que pueda ser utilizado para el análisis de patologías es un desafío técnico considerable.

- Heterogeneidad espacial y resolución espacial variable.

Los datos capturados por diferentes sensores pueden variar significativamente en términos de resolución espacial. Mientras que algunos sensores, como los escáneres láser terrestres, pueden generar datos de alta resolución que capturan detalles finos de la superficie de un edificio, otros, como los sensores de imágenes (cámaras),

pueden ofrecer una resolución más baja y una perspectiva más amplia, como se comentó en el capítulo 4.1. Esta disparidad puede dificultar la fusión de datos, ya que los detalles registrados por un sensor pueden no corresponder directamente con los de otro.

- Heterogeneidad espectral.

Los sensores pueden operar en diferentes rangos del espectro electromagnético, registrando distintos tipos de información. Por ejemplo, las cámaras térmicas detectan variaciones de temperatura, mientras que las cámaras multiespectrales pueden capturar información sobre la reflectancia de la superficie en varios rangos de onda. La integración de estos datos heterogéneos requiere métodos que puedan combinar eficazmente información espectral diversa para proporcionar una visión comprensiva de las características y patologías del edificio.

## 2. Volumen y complejidad de datos.

Las campañas de toma de datos con múltiples sensores generan grandes volúmenes de información que pueden ser difíciles de procesar y analizar con eficacia. La combinación de datos de diferentes sensores, como escáneres láser, cámaras multiespectrales y sensores térmicos, resulta en un volumen de datos extremadamente grande. Cada sensor puede generar millones de puntos de datos y su fusión multiplica el tamaño del conjunto de datos final. Este gran volumen presenta desafíos significativos para el almacenamiento, el procesamiento rápido y la visualización eficiente de los datos.

## 3. Complejidad en la interpretación de datos.

La complejidad de los datos fusionados no se limita a su volumen, sino que también incluye la interpretación de la información multiespectral y multidimensional. Cada sensor aporta una perspectiva única del objeto estudiado, y la combinación de estas perspectivas en un modelo coherente introduce una complejidad significativa en el análisis y la interpretación.

## 4. Necesidades computacionales elevadas.

El procesamiento de grandes volúmenes de datos complejos y heterogéneos exige capacidades de procesamiento avanzadas. Esto incluye *hardware* de alto rendimiento y algoritmos eficientes para manejar la carga de trabajo y realizar análisis en tiempos razonables.

## 5. Preservación de la integridad de los datos.

Mantener la integridad y calidad de los datos a lo largo del proceso de fusión es fundamental. Cualquier pérdida de información o introducción de errores puede comprometer la precisión del diagnóstico de patologías. La integridad de los datos se refiere a la exactitud y coherencia de los datos a lo largo del ciclo completo de su manejo, desde la adquisición hasta el análisis final. A su vez, en el proceso de fusión, es crucial mantener la riqueza de la información espectral capturada por los sensores. La pérdida de detalles espectrales puede resultar en una caracterización incompleta o incorrecta de las patologías.

6. Falta de métodos de análisis estandarizados.

Existe una falta de metodologías estandarizadas para el análisis de datos fusionados en la investigación de patologías. Esto puede llevar a la inconsistencia en los resultados y dificultar la comparación y validación de los hallazgos entre diferentes estudios e investigaciones. Hay que señalar también que los datos provienen de una variedad de sensores, cada uno con sus propios protocolos de captura, rangos operativos y resoluciones. Sin un método estandarizado para integrar estos datos heterogéneos, el análisis puede resultar inconsistente o incompleto.

7. Interpretación de datos fusionados.

La interpretación de datos complejos multisensor que resultan de la fusión de datos puede ser desafiante. Identificar patrones, correlaciones y anomalías significativas que indiquen la presencia de patologías requiere un profundo conocimiento tanto de la estructura del edificio como de las capacidades y limitaciones de los sensores utilizados. Sin un marco de análisis común, la interpretación de los datos fusionados puede ser altamente subjetiva, dependiendo de la experiencia y el juicio del investigador. Esto puede limitar la objetividad y reproducibilidad de las conclusiones extraídas.

Esto es fundamentalmente debido a que la gran cantidad de información disponible en los datos puede llevar a una sobrecarga de información, dificultando la identificación de los aspectos más relevantes para el análisis. Priorizar y filtrar la información clave es esencial para una interpretación efectiva. A su vez, los datos fusionados aportan una riqueza de información sobre las propiedades físicas, químicas y estructurales de los edificios estudiados, pero también introducen complejidades adicionales en su análisis e interpretación. Los datos procedentes de diferentes sensores pueden incluir información geométrica, térmica, espectral y estructural, cada una capturando diferentes aspectos del objeto de estudio.

La representación visual de datos multisensor es esencial para su interpretación, pero puede ser problemática debido a la dificultad de visualizar más de tres dimensiones simultáneamente. Encontrar métodos adecuados para representar y explorar estos datos es primordial para facilitar el análisis.

Identificar y extraer características relevantes de conjuntos de datos multisensor requiere técnicas avanzadas de procesamiento de datos. La detección de patrones, anomalías y correlaciones significativas dentro de estos datos es fundamental para el diagnóstico de patologías.

Enfrentar estos desafíos requiere perspectivas innovadoras, el desarrollo de metodologías, y una colaboración interdisciplinaria entre expertos en Geomática, arquitectura, ingeniería de la edificación y conservación del patrimonio. La investigación continua y el desarrollo de soluciones adaptadas son esenciales para superar estas barreras y mejorar la eficacia de la fusión de datos en la identificación y análisis de patologías en edificios.

Para salvar estas dificultades en el manejo y fusión de datos multisensor para el estudio y detección de patologías en estructuras edificadas, proponemos una serie de estrategias.

## 5.2 Posibles estrategias en la fusión de datos multisensor para la detección de patologías

Aquí expresamos posibles estrategias para la fusión de datos multisensor, enfocadas específicamente en la detección y la caracterización de patologías en edificaciones:

1. Análisis multinivel: llevar a cabo un análisis multinivel que permita integrar y analizar datos a diferentes escalas y niveles de detalle, aprovechando la información única aportada por cada tipo de sensor.
2. Técnicas de reducción de datos: implementar métodos de reducción de datos, como la voxelización, para disminuir el tamaño del conjunto de datos sin comprometer información crítica. Esto mejora la eficiencia del procesamiento y análisis al reducir la cantidad de datos a manejar, como ya hemos demostrado.
3. Visualización avanzada y herramientas de análisis: desarrollar y utilizar herramientas de visualización y análisis avanzadas diseñadas para manejar datos multisensor. Esto incluye software capaz de integrar y presentar información de múltiples fuentes sensoriales de manera intuitiva y accesible.
4. Métodos de fusión avanzados: desarrollar y aplicar algoritmos avanzados de fusión de datos capaces de manejar la heterogeneidad. Estos métodos pueden incluir técnicas de inteligencia artificial y aprendizaje automático que adaptan dinámicamente sus resultados basándose en las características de los datos de entrada.
5. Desarrollo de herramientas de *software* estándar: incentivar el desarrollo y uso compartido de herramientas de software que implementen métodos estandarizados de análisis. Esto podría incluir plataformas de código abierto que faciliten la fusión de datos, el análisis y la visualización.
6. Aprendizaje automático y análisis de datos (*big data*): emplear técnicas de aprendizaje automático y análisis de *big data* para extraer patrones, tendencias y anomalías de los conjuntos de datos complejos. Estos algoritmos pueden facilitar la interpretación automatizada de los datos y ayudar a identificar patologías en los edificios de manera más eficiente.
7. Colaboración interdisciplinar: establecer equipos de trabajo interdisciplinarios que aporten perspectivas distintas y diversas al proceso de investigación. La colaboración entre expertos en distintos campos de la ciencia e ingeniería puede enriquecer el desarrollo de métodos de análisis integrales y adaptados a las necesidades específicas del campo.

El trabajo publicado en este tercer artículo en el año 2024 en “*Heritage*”, revista científica de acceso abierto, va a abordar la fusión de datos multisensor a través de una metodología innovadora que integra la voxelización y los mapas auto organizativos (SOM) para estudiar patologías en edificaciones del Patrimonio Histórico. Pensamos que esta técnica ofrece un marco avanzado para el análisis detallado y la interpretación de las condiciones de los edificios, utilizando datos derivados de múltiples sensores geoespaciales.

El método aquí desarrollado se centra en la creación de modelos digitales tridimensionales

detallados mediante la voxelización de nubes de puntos capturados por diferentes sensores. Para ello se haremos uso de los vóxeles multispectrales, según se ha postulado su desarrollo y empleo en el capítulo 4, donde hemos analizado y comprobado su funcionamiento. Los vóxeles multispectrales, al integrar información multispectral en un formato tridimensional, facilitan la gestión eficiente de los datos capturados. Posteriormente, se aplicarán los mapas auto organizativos para clasificar estos vóxeles, permitiendo identificar patrones y características específicas de las estructuras y sus afecciones .

## 5.3 Sensores y campaña de toma de datos

### 5.3.1 Toma de datos

La campaña de toma de datos la realizamos en la Iglesia Visigoda de Santa María de Melque, situada en la provincia de Toledo (España). Este emblemático edificio del patrimonio histórico español se encuentra aproximadamente a 30 km al suroeste de la ciudad de Toledo, próximo al río Tajo.

La Iglesia Visigoda de Santa María de Melque (figura 5.1) no sólo es un destacado monumento del patrimonio histórico español por su antigüedad y conservación, sino que también representa una valiosa fuente de información para estudios arqueológicos y de conservación del patrimonio. La iglesia se construyó durante un período de transición en la Península Ibérica, cuando la región estaba bajo el dominio visigodo. Este contexto histórico proporciona un rico tapiz cultural y político que influyó en su arquitectura. La elección de la iglesia como objeto de estudio no es casual: representa uno de los ejemplos más completos y mejor conservados de la arquitectura visigoda, lo que ofrece oportunidades únicas para el estudio de las técnicas constructivas y los estilos arquitectónicos de la época.

La estructura de la iglesia de Santa María de Melque, construida en el siglo VII, se caracteriza por el uso de mampostería de grandes bloques ciclópeos de granito, con cubierta en bóveda de cañón sobre la nave central. La disposición de las naves en forma de cruz griega, el ábside recto y la disposición de los elementos arquitectónicos reflejan influencias romanas y bizantinas, evidenciando la rica diversidad cultural de la época [133].

La campaña de toma de datos se llevó a cabo únicamente en el exterior del edificio en febrero de 2022, cubriendo toda la estructura arquitectónica y sus elementos ornamentales.

Antes del registro de datos, se realizó una fase preparatoria meticulosa que implicó la colocación cuidadosa de una serie de objetivos de precisión en la superficie de los muros y en el terreno (figura 5.2). Estos marcadores identificados formaron un conjunto robusto de puntos de control que sirvieron como anclajes fundamentales para el proceso de recolección de datos subsiguiente. Asegurando la uniformidad y precisión en estos puntos de medición, se estableció un sistema de referencia georreferenciado (ETRS89-ETRF00 UTM 30), estandarizando efectivamente el proceso de adquisición de datos en todas las sesiones de recolección. Esta metodología rigurosa no solo aseguró la precisión de los datos recopilados, sino que también facilitó la comparabilidad y análisis sin problemas de la información recopilada.

Las señales de precisión en el terreno se midieron utilizando tecnología [GNSS](#), lo que permitió



**Figura 5.1:** Vista aérea del complejo arqueológico de Santa María de Melque (San Martín de Montalbán, Toledo - España)

obtener mediciones de alta precisión y confiabilidad. La implementación de receptores [GNSS](#) de doble frecuencia y el uso de antenas calibradas facilitaron la captura de datos geospaciales precisos, fundamentales para establecer un marco de referencia sólido para el estudio. El proceso meticuloso de medición, incluyendo sesiones de observación dobles, subraya el compromiso con la precisión y la reproducibilidad de los datos. Así queda demostrado con las precisiones de los puntos de apoyo y control, habiéndose obtenido desviaciones estándar en planimetría menos a 1 cm, cuyos detalles se pueden encontrar en el texto del artículo.

La meticulosa campaña de toma de datos, focalizada en la precisión y la integración de tecnologías avanzadas, proporcionó una base sólida para el análisis detallado de la iglesia. Esta metodología no solo mejora la comprensión del estado actual de la iglesia sino que también contribuye a la formulación de estrategias de conservación efectivas, resaltando el valor de las técnicas geomáticas avanzadas en la preservación del patrimonio cultural.

### 5.3.2 Sensores

Cada sensor utilizado proporciona una perspectiva única y complementaria, permitiendo una evaluación integral de las características arquitectónicas y potenciales patologías del edificio. A continuación, se ofrece la información sobre los sensores utilizados y su contribución al estudio:

- Cámara fotográfica Sony  $\alpha$  NEX-7



**Figura 5.2:** Señales en muro y pavimento para posterior georreferenciación

La cámara Sony  $\alpha$  NEX-7, equipada con una lente óptica de 19 mm, fue utilizada para registrar imágenes de alta resolución en el espectro visible. La selección de esta cámara y su lente específica permite una captura en detalle de las características superficiales del edificio, proporcionando datos valiosos para el análisis visual y la detección de deterioros superficiales visibles a simple vista. Las imágenes en las bandas roja, verde y azul, según su sensibilidad espectral (figura 4.3) son cruciales para la evaluación de las condiciones de la superficie y la identificación de cambios en el material o coloración que podrían indicar problemas subyacentes.

- Cámara fotográfica modificada Sony  $\alpha$  NEX-5N

La cámara Sony  $\alpha$  NEX-5N, modificada para capturar imágenes en el espectro infrarrojo cercano (NIR) y ultravioleta (UV) (figura 4.4), ofrece capacidades únicas para la detección de patologías detectadas en el espectro visible. La fotografía en banda NIR puede revelar problemas de humedad y otras alteraciones del material que no son

perceptibles en las imágenes en el espectro visible. Por otro lado, el uso de la fotografía **UV** facilita la identificación de restauraciones previas, contaminaciones biológicas y otros elementos que absorben o reflejan la luz **UV** de manera distinta al material original.

Estas dos cámaras ya las habíamos usado con éxito en el estudio en el que introdujimos el concepto de vóxel multispectral (capítulo 4).

- Escáner láser terrestre Faro Focus S350

El Faro Focus S350 (figura 5.3) es un escáner láser terrestre de alta precisión que registra datos tridimensionales detallados del edificio en estudio. La tecnología de escaneo láser basada en fase y la captura espectral en la banda **SWIR** permiten la creación de modelos 3D detallados de esta iglesia visigoda. Estos modelos son fundamentales para el análisis estructural, la identificación de deformaciones y fisuras y la evaluación de la integridad general del edificio. La resolución y precisión de los datos capturados por este escáner son esenciales para el diagnóstico de patologías [95]. Los detalles de este instrumento se pueden consultar en el artículo original adjunto.



**Figura 5.3:** Escáner láser Faro Focus S350

- Vehículo aéreo no tripulado (**UAV**) Parrot Anafi Thermal

El Parrot Anafi Thermal, con su sistema de cámara dual, aporta una perspectiva aérea valiosa al estudio, permitiendo la captura de imágenes **RGB** y térmicas infrarrojas. La capacidad de adquirir simultáneamente datos visuales y térmicos en una sola misión de vuelo ofrece una herramienta poderosa para la inspección remota. Las imágenes térmicas son particularmente útiles para detectar variaciones de temperatura en la superficie del edificio que pueden indicar problemas de aislamiento, humedades o flujos de aire anómalos. La perspectiva aérea también facilita la visualización de áreas de difícil acceso y proporciona una visión general de la distribución espacial de las patologías. Al igual que el equipo de escáner láser, las características de este equipo aéreo se describen en el artículo científico.

La combinación de estos sensores y sus capacidades específicas permite una comprensión multisensor de la iglesia visigoda bajo estudio. Mientras que las cámaras fotográficas ofrecen detalles sobre las condiciones superficiales y características multiespectrales, el escáner láser y el UAV aportan información geométrica y térmica crucial. La integración de estos datos tridimensionales multiespectrales mediante técnicas de fusión de datos proporciona una base sólida para la evaluación exhaustiva del edificio, permitiendo no solo identificar patologías existentes sino también priorizar intervenciones de conservación y restauración. Este análisis integrador tecnológicamente avanzado marca un hito importante en los esfuerzos por preservar y entender nuestro patrimonio cultural de manera más efectiva.

Se generaron varias nubes de puntos a través de diferentes métodos y sensores, resultando en datos detallados de la iglesia visigoda. Cada una de las nubes de puntos, excepto la obtenida por el escáner láser, provienen de un proceso fotogramétrico independiente. Es decir, todas las nubes de puntos derivadas de la fotogrametría son el resultado del procesamiento de un sólo sensor en un sólo proceso independiente, con la excepción de la nube de puntos RGB, en espectro visible, donde se combinaron imágenes tanto de la cámara RGB terrestre no modificada como del conjunto de imágenes RGB del UAV en el mismo proceso.

## 5.4 Voxelización multiespectral

Ya mencionado, la fusión de datos multisensor en el estudio de patologías en edificaciones históricas, como la Iglesia Visigoda de Santa María de Melque, es un proceso que aborda desafíos complejos en la conservación del patrimonio.

Como hemos estudiado, la voxelización convierte las nubes de puntos obtenidas en una representación regular y estructurada del espacio. Cada vóxel multiespectral, en este caso, representa un volumen en el espacio tridimensional con propiedades asignadas basadas en los datos de entrada. Este proceso ofrece varias ventajas clave para el análisis estructural y la identificación de patologías en edificaciones históricas (sección 4.6)

Así, en nuestro estudio, examinamos cómo el tamaño elemental de los vóxeles afecta la distribución de puntos dentro de las nubes. De esta forma, se crearon estructuras de vóxeles con varios tamaños elementales (50 cm, 25 cm, 10 cm, 5 cm y 3 cm). El punto de partida para la creación de estructuras de vóxel fue la nube de puntos RGB, dada su cobertura completa del edificio. En casos donde un vóxel específico contenía múltiples puntos de una banda espectral particular, la propiedad espectral del vóxel se estableció en el valor medio de esos puntos, calculando también estadísticas adicionales como valores máximos, mínimos y varianza. Así, el vóxel efectivamente se convierte en un vóxel multiespectral.

Para gestionar las nubes de puntos y su voxelización, se utilizó software propio desarrollado en lenguaje *Python* basado en la librería Open3D y se generaron histogramas que muestran el número de puntos por vóxel en cada banda espectral, proporcionando una visión clara de cómo los puntos se distribuyen a lo largo de la estructura vóxel.

## 5.5 Mapas auto organizados

Los *Self-Organizing Map*, Mapa auto organizado (SOM), desarrollados por Teuvo Kohonen en los años 80 [45], son una clase de redes neuronales artificiales que se entrenan utilizando un aprendizaje no supervisado para producir una representación discreta de dimensión menor (típicamente bidimensional) de un espacio de entrada de mayor dimensión, preservando las propiedades topológicas del espacio original. Este tipo de red neuronal se caracteriza por su capacidad para organizar datos complejos en agrupaciones que facilitan la visualización y análisis de patrones, correlaciones y anomalías dentro de grandes conjuntos de datos.


### 5.5.1 Principios básicos de los SOM

Los SOM operan mediante competencia entre sus neuronas. Cada neurona en el mapa está asociada con un vector de peso de la misma dimensión que los vectores de entrada. Durante el entrenamiento, se presenta al mapa una serie de vectores de entrada, y para cada uno, la neurona cuyo vector de peso es más similar al vector de entrada -la neurona ganadora o *Best Matching Unit*, Unidad de Mejor Correspondencia (BMU)- se ajusta para acercarse más al vector de entrada. Este ajuste no se limita a la neurona ganadora, sino que también se aplica a sus vecinas en el mapa, aunque en menor medida, decreciendo con la distancia desde la neurona ganadora. Este proceso permite que el mapa aprenda la distribución de los vectores de entrada, organizándolos de manera que vecindades físicas en el mapa correspondan a vecindades estadísticas en el espacio de datos.

La estructura y funcionamiento de los mapas auto organizados es [21]:

- Estructura de la red: un SOM consiste en una capa de entrada y una capa de salida o mapa de características, organizada típicamente como una matriz bidimensional de nodos o neuronas. Cada neurona en la capa de salida está completamente conectada a todas las neuronas de la capa de entrada mediante pesos sinápticos (figura 5.4).
- Inicialización: al inicio, los pesos sinápticos se inicializan generalmente de manera aleatoria. Sin embargo, técnicas de inicialización más sofisticadas pueden mejorar la convergencia y calidad del mapa resultante.
- Competencia: cuando se presenta un vector de entrada, todas las neuronas en la capa de salida compiten entre sí para activarse. La neurona cuyos pesos sinápticos sean más similares al vector de entrada (usualmente determinado por la distancia euclidiana) se declara ganadora y se conoce como la unidad de mejor coincidencia (BMU).
- Cooperación y adaptación: la BMU y sus neuronas vecinas en la matriz de salida ajustan sus pesos para acercarse más al vector de entrada. Este proceso se rige por una función de vecindad que determina el grado de influencia que la BMU ejerce sobre sus vecinos. La tasa de aprendizaje, que decrece con el tiempo, controla la magnitud del ajuste de los pesos.
- Organización topológica: a través de iteraciones sucesivas, los pesos de las neuronas se ajustan de manera que los patrones similares de los datos de entrada activan neuronas cercanas en la matriz de salida, también denominada capa de Kohonen (figura 5.4).

El resultado es una estructura donde la posición de cada neurona en el mapa refleja patrones intrínsecos y relaciones en los datos de entrada.



**Figura 5.4:** Estructura típica de un mapa autoorganizado (fuente: [32])

Entre las ventajas y aplicaciones de los mapas autoorganizados podemos encontrar [21]:

- Estructura topológica.

Los **SOM** mantienen la relación topológica de los datos de entrada, lo que significa que patrones similares en los datos originales se ubican cerca uno del otro en el mapa generado. Esto ayuda a identificar agrupaciones naturales de datos y relaciones entre diferentes variables.

- Agrupación de datos.

Pueden descubrir agrupaciones naturales en los datos y asignar etiquetas a nuevos datos basándose en estas agrupaciones.

- Reducción de ruido.

La agrupación y el promedio realizados durante el entrenamiento de un **SOM** pueden ayudar a suavizar el ruido en los datos.

- Aprendizaje no supervisado: a diferencia de otros métodos que requieren datos etiquetados para el entrenamiento, los **SOM** aprenden la estructura de los datos de entrada sin necesidad de etiquetas, clasificando la información basándose únicamente en las características intrínsecas de los datos.

- *Clustering* y segmentación.

Al organizar los datos de entrada en regiones contiguas en el mapa, los **SOM** facilitan la identificación de *clusters* o segmentos dentro de los datos, lo que puede ser invaluable para la segmentación de mercado, análisis de clientes, o detección de patologías en aplicaciones médicas o estructurales.

- Reducción de dimensionalidad.

Aunque los SOM no son técnicamente una técnica de reducción de dimensionalidad, su capacidad para proyectar datos de alta dimensión en un espacio de menor dimensión los hace útiles para explorar y entender la estructura subyacente de los datos.

- Visualización intuitiva.

La representación bidimensional resultante facilita la interpretación y visualización de relaciones complejas entre los datos, lo que es particularmente útil para expertos no especializados en análisis de datos.

- Clasificación de patologías.

Al agrupar datos basados en similitudes, los SOM pueden ayudar a identificar áreas con características comunes que pueden indicar la presencia de patologías específicas en la estructura del edificio.

En el contexto del estudio de patologías en edificaciones, como la Iglesia Visigoda de Santa María de Melque, los SOM permiten integrar y analizar datos multisensor, incluyendo información geométrica y multiespectral. La capacidad de los SOM para organizar esta información diversa en un formato coherente y de fácil interpretación facilita la identificación de áreas problemáticas, patrones de deterioro y otros aspectos críticos para la conservación y restauración del patrimonio cultural. Al aplicar SOM, los investigadores podemos transformar grandes volúmenes de datos complejos y aparentemente dispares en conocimientos que guíen las decisiones de conservación, destacando el valor de las técnicas avanzadas de análisis de datos geomáticos en el campo de la preservación del patrimonio.

## 5.5.2 Índices de calidad en los mapas auto organizados

Hemos empleado índices de calidad específicos para evaluar la efectividad de los mapas auto organizados (SOM) utilizados en el análisis de los datos recopilados de la Iglesia Visigoda de Santa María de Melque [82]. Estos índices son cruciales para optimizar el tamaño del mapa y asegurar una representación precisa y significativa de los datos multisensor fusionados. A continuación, describiremos en detalle los índices de calidad mencionados en el artículo:

- Error de cuantificación (QE)

El error de cuantificación (Quantization Error, QE) es una medida fundamental que evalúa la calidad de un SOM, cuantificando el error promedio de distancia entre cada vector de datos de entrada y el vector de pesos de su BMU correspondiente [82]. El QE se obtiene a partir de la salida del SOM tras el aprendizaje y expresa matemáticamente la distancia al cuadrado (normalmente la distancia euclídea media) entre los datos de entrada  $x$  y sus correspondientes BMU [28]. Así, el QE refleja la distancia media entre cada vector de datos ( $X$ ) y su BMU:

$$QE = 1/N \sum_{i=1}^N \|X_i - (BMU_{(i)})\|, \quad (5.1)$$

donde  $N$  es el numero de vectores  $x$  del conjunto de entrenamiento .

Un **QE** más bajo indica que los vectores de peso de las neuronas en el **SOM** están más cerca de los vectores de entrada, sugiriendo una representación más precisa de los datos en el mapa. El **QE** es particularmente útil para evaluar lo bien que el **SOM** ha aprendido a modelar los datos y para comparar la efectividad de diferentes configuraciones de tamaño de mapa.

- Producto topográfico (TP)

El producto topográfico (Topographic Product, **TP**) es otro índice de calidad empleado para evaluar los **SOM**. Este índice mide la preservación de las relaciones topológicas entre los vectores de entrada en el espacio de alta dimensión y su representación en el mapa de características de baja dimensión [9]. Un buen **SOM** debería asegurar que vectores de entrada similares activen neuronas cercanas en el mapa, manteniendo así la topología de los datos. El **TP** evalúa si los vecinos cercanos en el espacio de datos original permanecen cercanos en el mapa **SOM**, lo que es fundamental para una representación fiel de las estructuras de datos subyacentes.

Tras la fase de aprendizaje, el producto topográfico se calcula del siguiente modo [9]: para cada nodo del espacio de salida  $j$ , se calcula el orden del vecino más próximo en el espacio de entrada y en el espacio de salida ( $n_k^A(j)$  es el  $k$ -ésimo vecino más próximo de  $j$  en  $A, n_k^V(j)$  en  $V$ ). A partir de estas cantidades, definimos los ratios  $Q_1$  y  $Q_2$  (Ecuaciones 5.2 y 5.3)

$$Q_1(j, k) = \frac{d^V(\mathbf{w}_j, \mathbf{w}_{n_k^A(j)})}{d^V(\mathbf{w}_j, \mathbf{w}_{n_k^V(j)})}, \quad (5.2)$$

$$Q_2(j, k) = \frac{d^A(j, n_k^A(j))}{d^A(j, n_k^V(j))}. \quad (5.3)$$

Para obtener una medida global simétrica, multiplicamos  $Q_1$  y  $Q_2$ , obteniendo  $P_3$ :

$$P_3(j, k) = \left( \prod_{l=1}^k Q_1(j, l) Q_2(j, l) \right)^{\frac{1}{2k}}. \quad (5.4)$$

El promedio de todos los nodos y órdenes de vecindad da como resultado el producto topográfico (**TP**):

$$TP = \frac{1}{N(N-1)} \sum_{j=1}^N \sum_{k=1}^{N-1} \log(P_3(j, k)). \quad (5.5)$$

Un **TP** cercano a cero indica una preservación topológica excelente, mientras que valores más altos sugieren distorsiones en la representación de las relaciones entre los datos.

La aplicación de estos índices en el artículo nos permitió ajustar el tamaño del **SOM** para equilibrar la precisión de la representación (minimizando el **QE**) y la preservación de la

estructura topológica de los datos (optimizando el **TP**). Estos índices son esenciales no solo para asegurar una fusión adecuada de los datos de diferentes sensores sino también para facilitar la extracción de indicios significativos a partir de los patrones y agrupaciones revelados por el **SOM**. La optimización basada en el **QE** y el **TP** garantiza que el mapa resultante sea tanto preciso como informativo, proporcionando una base sólida para la identificación de patologías y características arquitectónicas de interés en la iglesia.

## 5.6 Metodología y resultados

En la sección de resultados del artículo presentamos un análisis detallado sobre la implementación y los resultados obtenidos mediante el uso de mapas auto organizados (**SOM**) para la clasificación de estructuras de vóxel multiespectrales derivadas de las nubes de puntos de la Iglesia Visigoda de Santa María de Melque. La metodología que hemos seguido se detalla a continuación.

### 5.6.1 Determinación del tamaño óptimo del mapa SOM

Se realizaron entrenamientos de **SOM** para diferentes tamaños de vóxel, determinando el tamaño óptimo del mapa de manera que el Producto Topográfico (**TP**) fuera mínimo en valor absoluto. La normalización de los datos de los vóxeles multiespectrales mediante una escala mín-máx fue un paso crítico para facilitar el proceso de entrenamiento y la convergencia del modelo.

La determinación del tamaño óptimo del mapa de **SOM** es un paso crucial en el proceso de análisis de datos utilizando mapas auto organizados. Este proceso implica elegir una configuración que no solo capture la complejidad inherente a los datos de entrada, sino que también permita una interpretación clara y útil de los resultados. La selección adecuada del tamaño del mapa influye directamente en la capacidad del **SOM** para realizar una representación fiel y útil de los datos, afectando tanto la precisión de la cuantificación como la preservación de las relaciones topológicas.

Para determinar el tamaño óptimo del mapa **SOM**, se utilizó, como se ha mencionado, el Producto Topográfico (**TP**) junto con la regla empírica 5.6 [9] que relaciona el número de vóxeles completos (es decir, con al menos un punto de datos en cada una de las nubes de puntos a fusionar) con el tamaño del mapa:

$$k = 5\sqrt{N}, \quad (5.6)$$

donde  $k$  es el tamaño del mapa (número de neuronas en la capa de Kohonen) y  $N$  es el número de vóxeles completos en la estructura voxelizada. Esta fórmula proporciona un punto de partida para la selección del tamaño del mapa, ajustando el número de neuronas para cubrir adecuadamente la variabilidad en los datos.

Con los índices de calidad calculados para diferentes tamaños de mapas **SOM**, el proceso de optimización busca minimizar el **QE** y encontrar el valor de **TP** más cercano a cero, indicando

así el tamaño de mapa que mejor equilibra la precisión de la cuantificación con la preservación de la topología de los datos.

En este trabajo hemos realizado distintos entrenamientos del SOM para los diferentes tamaños de vóxeles, determinando para cada caso el tamaño de mapa óptimo basado en el TP y el QE obtenidos. Esta aproximación sistemática permite identificar el tamaño de mapa que proporciona la mejor representación de los datos multisensor fusionados para su posterior análisis, como la identificación de patologías en las edificaciones.

### 5.6.2 Análisis y visualización de los SOM

Para el análisis de los resultados obtenidos según el entrenamiento de los mapas auto organizados, disponemos de una serie de herramientas de visualización.

La representación de las distancias entre neuronas, conocida como U-Matrix (*Unified Distance Matrix*), es una herramienta visual clave para interpretar mapas auto organizados [105]. La U-Matrix ofrece una representación gráfica de las distancias o diferencias entre neuronas adyacentes en el mapa de características del SOM, facilitando la identificación de clústeres y la comprensión de la estructura de los datos en un espacio reducido. Estas distancias reflejan la disimilitud en los vectores de peso asociados a cada neurona, que a su vez representan los patrones de los datos de entrada.


Las distancias calculadas se visualizan en un mapa donde cada punto (o área) representa una neurona en el SOM. Los valores de distancia más altos indican una mayor disimilitud entre neuronas vecinas, mientras que los valores más bajos sugieren similitud. Por lo general, los valores más altos se representan con colores más claros o más cálidos, y los valores más bajos con colores más oscuros o más fríos.

Las áreas de la U-Matrix con valores de distancia bajos indican regiones del SOM donde las neuronas son similares entre sí, sugiriendo la presencia de un clúster de datos [32]. Por otro lado, las regiones con valores altos actúan como fronteras entre clústeres, donde las neuronas representan patrones de datos significativamente diferentes (figura 5.5).

La distribución de activaciones de neuronas en el contexto de mapas auto organizados se refiere a cómo diferentes áreas del mapa SOM responden a los datos de entrada durante el proceso de aprendizaje y mapeo. Esta distribución es una representación visual de la frecuencia con la que cada neurona ha sido seleccionada como BMU para los vectores de entrada durante el entrenamiento del SOM. Analizar esta distribución puede ofrecer pistas sobre la estructura de los datos y cómo se organizan espacialmente dentro del mapa.


En un SOM, cada neurona aprende a especializarse en una parte específica del espacio de entrada, ajustando sus pesos para representar los patrones o características de los datos de entrada que le son más similares. A lo largo del entrenamiento, algunas neuronas se activarán más frecuentemente que otras, dependiendo de la densidad y distribución de los datos de entrada. La activación de una neurona ocurre cuando se identifica como la BMU para un vector de entrada dado.

La visualización de la distribución de activaciones se puede realizar mediante histogramas o



**Figura 5.5:** Matriz de distancia entre neuronas (U-Matrix) correspondiente al SOM con tamaño elemental de vóxel 5 cm.

mapas de calor superpuestos en el SOM. Estas visualizaciones permiten observar rápidamente qué áreas del mapa están más activas y cómo se distribuyen estas activaciones en relación con la estructura de los datos.



**Figura 5.6:** Mapa de calor (*heatmap*) correspondiente al SOM con tamaño elemental de voxel 5 cm.

### 5.6.3 Identificación y localización de patologías

Hasta aquí se ha descrito como se pueden interpretar los resultados obtenidos mediante el uso de mapas auto organizativos aplicados a vóxeles multiespectrales para el estudio de patologías en edificaciones históricas. Los resultados obtenidos a través de los SOM, al analizar las características multiespectrales de los vóxeles, facilitan la identificación de patrones y características específicas de las estructuras y sus afecciones, para avanzar en el estudio de patologías en la edificación.

Cada neurona en el mapa generado por el SOM representa un grupo de vóxeles con características similares, basadas en los vectores de peso asignados a cada propiedad espectral

en la capa de entrada. Esto permite que el modelo clasifique eficientemente los vóxeles en función de su similitud espectral, ofreciendo una representación detallada y organizada de la estructura del edificio y sus posibles problemas.

En el mapa de calor generado por el SOM para vóxeles de 5 cm. (figura 5.6), es posible distinguir qué neuronas marcan patrones más definidos, debido a que se activan con mayor frecuencia. Las neuronas situadas en las esquinas del mapa de calor sobresalen particularmente:

- La neurona con índice (0, 0), que se activa con 274 vóxeles. Esta neurona muestra una predominancia de la banda roja y del láser (SWIR), mientras que las bandas UV y térmica influyen menos en estos vóxeles. Estos se encuentran mayoritariamente en la fachada sur del edificio
- Por otro lado, la neurona en (0, 33), con 425 vóxeles activados, destaca por la importancia de la banda del láser escáner. Las otras bandas, como las RGB y la UV, presentan una influencia media y la información térmica es menos relevante. Los vóxeles asociados a esta neurona se localizan en las partes del edificio que no reciben luz solar directa durante la captura de datos.
- La neurona en (33, 0), que activa 621 vóxeles, se caracteriza por un fuerte componente en la banda térmica, siendo la banda UV la que menos contribuye. Las bandas roja y verde, así como la NIR, tienen una influencia moderada, y la banda del láser (SWIR) también es significativa. Los vóxeles correspondientes a esta neurona están en la fachada norte.
- Finalmente, la neurona en (33, 33), que se activa con 136 vóxeles, tiene una marcada predominancia en la banda del láser escáner, mientras que las otras bandas, incluidas la RGB, NIR, UV y térmica, presentan menores pesos.

Durante la campaña de toma de datos en el edificio de Santa Maria del Melque, se detectó una zona afectada por humedad situada en la parte baja de una de las fachadas orientadas hacia el norte, como se ilustra en la figura 5.7. Es bien sabido que la presencia de humedad en las estructuras puede acarrear una serie de problemas estructurales y de conservación significativos. Entre estos, destaca la formación de eflorescencias salinas, caracterizadas por ser depósitos blancos que aparecen en las superficies. Estos depósitos son el resultado directo de la migración de sales solubles en el agua, que se van desplazando a través de los poros de los materiales constructivos por capilaridad desde el suelo hacia las paredes. Este fenómeno es especialmente común en situaciones donde el agua subterránea, rica en sales minerales, asciende por los muros. Adicionalmente, la humedad no solo propicia la aparición de eflorescencias salinas sino que también es un factor determinante en el crecimiento de moho, en la aceleración de procesos de deterioro material y en la emergencia de problemas estructurales que comprometen la integridad del edificio.

Con el objetivo de profundizar en la hipótesis sobre la viabilidad de aplicar vóxeles multispectrales en el contexto de la fusión de datos obtenidos de múltiples sensores, para así estudiar las patologías estructurales mediante el empleo de mapas auto organizativos, dirigimos nuestra atención específicamente hacia aquellos vóxeles que evidenciaban la presencia de anomalías patológicas en la estructura. El primer paso fue identificar las BMU correspondientes a estos




**Figura 5.7:** Presencia de humedad y zonas de eflorescencias en muro fachada norte en Santa Maria de Melque

vóxeles, revelando que se encontraban en una ubicación próxima a la neurona (33, 20). Para mostrar su vector de pesos dentro del estudio, se generó la grafica característica asociada a esta neurona (figura 5.8). Dicha gráfica demuestra una correlación marcada entre las bandas del espectro visible y la banda utilizada por el escáner láser (infrarrojo de onda corta [SWIR](#)).

Estudios anteriores sobre la detección de patologías por humedades [26] han demostrado que el espectro infrarrojo, en particular las bandas de 778 nm, 905 nm y 1550 nm, es eficaz para identificar estas zonas con humedad. Los datos más precisos se obtuvieron con el uso del infrarrojo de onda corta [SWIR](#), en el entorno de los 1550 nanómetros. Las bandas visibles también pueden identificar eflorescencias debido a que las superficies afectadas reflejan más luz en estos rangos espectrales. Esto concuerda con la información de la neurona (33,20) donde las bandas visibles [RGB](#) y, más principalmente, la banda láser [SWIR](#) presentan los pesos de mayor valor. Se puede demostrar así que esta metodología de fusión de datos multisensor mediante vóxeles multiespectrales y su análisis a través de mapas auto organizados caracteriza y agrupa correctamente vóxeles con este comportamiento espectral y, consecuentemente, con posibles patologías.

## 5.7 Conclusiones

La metodología propuesta de fusión y entrenamiento probó ser altamente efectiva al utilizar directamente las nubes de puntos 3D originales, combinando datos geométricos tridimensionales



**Figura 5.8:** Curva característica de pesos de la neurona (33,20). En el eje de abcisas aparecen las distintas bandas espectrales, mientras que en el eje de ordenadas se expresan sus pesos

con información multiespectral, evitando la necesidad de transformar nubes de puntos en imágenes para la detección y análisis de patologías. Este tratamiento permite una identificación y localización geoespacial precisa de problemas como la humedad, brindando herramientas innovadoras para la preservación efectiva del patrimonio cultural.

La validez de esta aproximación se refuerza al asociar las bandas del espectro visible y las obtenidas por el escáner láser, observando una fuerte correlación en las áreas identificadas con humedad. Este resultado confirma la efectividad de los SOM para procesar y clasificar la información contenida en los vóxeles multiespectrales, permitiendo una localización precisa de las patologías. Además, los resultados son coherentes con estudios previos [24, 25, 26] que resaltan la utilidad de las bandas espectrales infrarrojas, específicamente en longitudes de onda de 778 nm, 905 nm y 1550 nm, para la detección de humedad en estructuras.

La metodología no solo identifica con precisión las áreas afectadas por la humedad, sino que también ofrece una herramienta avanzada para el diagnóstico y la conservación del patrimonio arquitectónico, alineándose con los objetivos de preservación y mantenimiento efectivos del edificio.

En este sentido, este trabajo revoluciona el estudio y la conservación de edificios históricos, permitiendo una comprensión más profunda y detallada de sus condiciones estructurales y patologías mediante el análisis integrado de datos geoespaciales y espectrales, tratados mediante voxelización y SOM.



*heritage*

IMPACT  
FACTOR  
1.7

CITESCORE  
2.8

Article

---

# Deep Learning Enhanced Multisensor Data Fusion for Building Assessment Using Multispectral Voxels and Self- Organizing Maps

---

Javier Raimundo, Serafin Lopez-Cuervo Medina, Julian Aguirre de Mata,  
Tomás Ramón Herrero-Tejedor and Enrique Priego-de-los-Santos

## Special Issue

Conservation Methodologies and Practices for Built Heritage

Edited by

Dr. Daniela Fico and Daniela Rizzo



<https://doi.org/10.3390/heritage7020051>

Article

# Deep Learning Enhanced Multisensor Data Fusion for Building Assessment Using Multispectral Voxels and Self-Organizing Maps

Javier Raimundo <sup>1,\*</sup>, Serafin Lopez-Cuervo Medina <sup>1</sup>, Julian Aguirre de Mata <sup>1</sup>, Tomás Ramón Herrero-Tejedor <sup>2</sup>  
and Enrique Priego-de-los-Santos <sup>3</sup>

- <sup>1</sup> Departamento de Ingeniería Topográfica y Cartográfica, Escuela Técnica Superior de Ingenieros en Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, Campus Sur, A-3, Km 7, 28031 Madrid, Spain; s.lopezc@upm.es (S.L.-C.M.); julian.aguirre@upm.es (J.A.d.M.)
- <sup>2</sup> Departamento de Ingeniería Agroforestal, Universidad Politécnica de Madrid, Campus Ciudad Universitaria, Av. Puerta de Hierro, n° 2–4, 28040 Madrid, Spain; tomas.herrero.tejedor@upm.es
- <sup>3</sup> Department of Cartographic Engineering, Geodesy and Photogrammetry, Universitat Politècnica de València, Camí de Vera s/n, 46022 Valencia, Spain; epriego@cgf.upv.es
- \* Correspondence: ajraimundo@alumnos.upm.es

**Abstract:** Efforts in the domain of building studies involve the use of a diverse array of geomatic sensors, some providing invaluable information in the form of three-dimensional point clouds and associated registered properties. However, managing the vast amounts of data generated by these sensors presents significant challenges. To ensure the effective use of multisensor data in the context of cultural heritage preservation, it is imperative that multisensor data fusion methods be designed in such a way as to facilitate informed decision-making by curators and stakeholders. We propose a novel approach to multisensor data fusion using multispectral voxels, which enable the application of deep learning algorithms as the self-organizing maps to identify and exploit the relationships between the different sensor data. Our results indicate that this approach provides a comprehensive view of the building structure and its potential pathologies, and holds great promise for revolutionizing the study of historical buildings and their potential applications in the field of cultural heritage preservation.

**Keywords:** multisensor; data fusion; voxel; multispectral; building; point cloud; cultural heritage



**Citation:** Raimundo, J.; Medina, S.L.-C.; Mata, J.A.d.; Herrero-Tejedor, T.R.; Priego-de-los-Santos, E. Deep Learning Enhanced Multisensor Data Fusion for Building Assessment Using Multispectral Voxels and Self-Organizing Maps. *Heritage* 2024, 7, 1043–1073. <https://doi.org/10.3390/heritage7020051>

Academic Editors: Daniela Fico and Daniela Rizzo

Received: 2 January 2024

Revised: 1 February 2024

Accepted: 2 February 2024

Published: 17 February 2024



**Copyright:** © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

Picture a historical building as an enigmatic puzzle, each crack, deformation, and hidden corrosion forming the cryptic pieces waiting to be deciphered. As we stand at the intersection of technology and architectural history, our pursuit is to decode this intricate puzzle. Multisensor data fusion emerges as our toolkit, seamlessly blending the precision of laser scanners with the spectral insight of photographic cameras. Here, we introduce a revolutionary approach, not just to study buildings, but to unravel the mysteries concealed within their weathered walls.

The state-of-the-art in multisensor data fusion in the study of building pathologies has undergone significant advances in the last decades. The convergence of various technologies and sensors has enabled researchers to assess structural conditions and pathologies in buildings more fully and accurately [1,2].

Studies on potential issues in historical buildings employing geomatic sensor technology have garnered diverse attention in late years [3,4]. First approaches were dedicated only to generate three-dimensional models with different levels of detail. These three-dimensional models were complemented by spectral information so that visual representations could be made to highlight areas that could present some pathology [5,6].

Various studies have focused on different architectural elements and their specific pathologies. For example, in the study of façades [7–9] or concrete structural elements [10–12].

The data obtained were sometimes integrated into Building Information Models (BIM) for further study [13,14].

In turn, different research works have concentrated on the use of singular sensors. There are research works focused on the use of infrared thermal cameras [15–19], multi-spectral photographic cameras [20,21] and laser scanners [22–24].

The combined use of active and passive sensors such as terrestrial laser scanners and photographic cameras with different spectral sensitivities has provided a wealth of information. This allows the generation of detailed three-dimensional models, point clouds with spectral information, and visual representations highlighting the affected areas. This combination of different sensor types provides a complete view of the structure and its potential pathologies. Terrestrial laser scanners capture highly detailed three-dimensional point clouds, thereby facilitating the detection of structural deformations and cracks [25,26]. Photographic cameras provide valuable spectral information that can indicate signs of corrosion, moisture, or other problems that can not be visible to the naked eye.

The use of 3D point clouds requires the management of an immense volume of data, which requires substantial data-processing infrastructure for handling and visualization. Additionally, 3D point clouds are inherently unstructured, making the task of locating specific points within these clouds nontrivial [27]. One consequence of this lack of structure is that point clouds do not contain topological information, thereby precluding an understanding of neighborhood relationships among points [28].

Point clouds also exhibit non-uniform densities and distributions. The point density achieved is not always optimal for the intended applications. Some areas will display redundant information, particularly in the overlapping zones between scans. Conversely, other areas will present lower point densities. This results in heterogeneity in both the density and accuracy of points within the cloud [29].

In terms of analysis, multisensor data fusion has enabled the early detection and monitoring of structural pathologies, such as cracks, deformations, and corrosion. In addition, the integration of information from airborne and ground sensors has enabled more complete coverage of structures, both in terms of physical access and data diversity. Traditionally, the assessment of structural problems involves visual inspections, manual measurements, and, at best, the use of a single sensor to capture limited data [30]. Modern data fusion systems allow the creation of accurate three-dimensional digital models that can be compared to the original designs to identify discrepancies. This is especially valuable for assessing the performance of historic structures and monuments where preservation is critical [31].

The integration of various sensors and techniques also leads to the creation of diverse point cloud datasets, which in turn contributes to the formation of large data repositories [29]. This not only affects processing speed but also requires the conversion of substantial volumes of point data into dependable and actionable insights. Traditional methods for customizing point clouds for specific applications are becoming increasingly time consuming and require manual intervention. The growing complexity and volume of data, often spread across multiple stakeholders or platforms, pose a challenge to human expertise in effective data management [32]. To facilitate more effective decision making, it is crucial to efficiently convert voluminous point cloud data into streamlined processes, thereby heralding a new age of decision-support services. Strategies must be developed for extensive automation and structuring to eliminate the need for task-specific manual processing and to promote sustainable collaboration.

Voxels have been used in a variety of distinct fields, including geology [33], forest inventory [34], and medical research [35]. In the context of their application to point cloud management, multiple studies [36–40] have substantiated the efficacy of voxels as an appropriate tool for handling point cloud data.

Voxelization is more beneficial for managing raw 3D point clouds. With the points being placed in a regular grid pattern, it is now possible to structure the point cloud in a tree format that allows for significantly reduced computing time. Logical inference is also

possible from a voxel structure because the known relationship with neighboring points allows for semantic reasoning [41].

In voxelization of point clouds, one defining parameter of the voxel structure is the elemental voxel size. This parameter governs the resolution of the phenomena under study through the data structure, impacting various applications, such as finite elements [42], structural analyses [43,44], and dynamic phenomena [45]. For instance, if a study or simulation requires a resolution of 5 cm, this would dictate the voxel elemental size established during the voxelization process. In addition, voxel size determines the extent of element reduction relative to the number of points present in the original clouds [29].

The application of deep learning algorithms to voxel structures is an active research area across various fields, such as computer vision, robotics, geography, and medicine. Within the spectrum of deep learning approaches applied to voxels, some notable methodologies as 3D Convolutional Neural Networks (3D CNNs) [46,47], Voxel-based Autoencoders [48,49], Generative Networks for Voxels [50–52], and Semantic Segmentation [28,53] have been used.

However, despite these advances, challenges still exist in terms of accurate calibration, data correction, and effective integration of the collected information. Additionally, the interpretation of merged data requires expertise in remote sensing and structural analysis to avoid false diagnoses. Accurate integration of data from different sources requires careful calibration and correction [54]. In addition, proper interpretation of results remains crucial, as the presence of detailed data does not always guarantee a complete understanding of the underlying causes of pathologies.

In this paper, we present a novel approach to multisensor data fusion using multispectral voxels. This data fusion allows for optimal and efficient management of the sensors information, allowing later applications of deep learning algorithms. With this, a workflow is determined that allows the study of buildings as well as the possible pathologies that could be present on them.

This study is organized as follows. Initially, the sensors that were used in a data acquisition campaign on a prominent Spanish Cultural Heritage building are described. Subsequently, the methodology that was designed for handling, processing, and fusing the data using our concept of multispectral voxels is outlined. The deep learning Self-organizing map algorithm will be applied to our multispectral voxel structure. Finally, we discuss the results.

## 2. Materials and Methods

### 2.1. Sensors

Within the context of multisensor fusion, a data-capture campaign with a range of different sensors featuring distinct spectral sensitivities and types were chosen. To this end, active and passive sensors were used. The set of active sensors comprises terrestrial laser scanners, whereas the passive sensor group encompasses a variety of photographic cameras deployed in both terrestrial and aerial arrangements using Unmanned Aerial Vehicles (UAVs). Each camera had distinct spectral sensitivities.

This meticulous selection of sensors encompasses various conventional modalities of geospatial data capture, which are commonly employed in the analysis of buildings and architectural structures. The acquired data were subjected to a series of processing techniques, with photogrammetry as one of the principal methodologies. Consequently, the final output consisted of multiple point cloud datasets, each characterized by unique and significant spectral properties.

While developing the data capture strategy, it was acknowledged that not all sensors were capable of capturing data encompassing the entire built structure. Sensors located on the ground can only provide information about the lower sections of the building, while sensors attached to aerial vehicles can capture data covering the entire architectural unit. This distinction is essential for accurate interpretation and cohesive integration of the collected data during the analytical process.

The employed sensors are described herein, including photographic cameras, unmanned aerial sensors (UAVs), and laser scanners:

- The terrestrial digital imaging device deployed was a Sony NEX-7 photographic camera (Sony Corporation, Tokyo, Japan), a model equipped with a 19 mm optical lens of fixed length. This particular sensor captures spectral components within the red (590 nm), green (520 nm), and blue (460 nm) bands of the visible spectrum. The spectral response of this camera is illustrated in Figure 1a, and its specific parameters are outlined in Table 1.

**Table 1.** Sony NEX 7 camera sensor parameters.

Parameter	Value
Sensor	APS-C type CMOS sensor
Focal length (mm)	19
Sensor width (mm)	23.5
Sensor length (mm)	15.6
Effective pixels (megapixels)	24.3
Pixel size (micrometers)	3.92
ISO sensitivity range	100–1600
Image format	RAW (Sony ARW 2.3 format)
Weight (g)	350

- A modified version of the digital image camera, the Sony NEX-5N model, was also employed in terrestrial positions. It was outfitted with a 16 mm fixed-length lens, accompanied by a near-infrared (NIR) filter and an ultraviolet (UV) filter in different shot sessions. Detailed information on this sensor is provided in Table 2.

**Table 2.** Sony NEX 5N camera sensor parameters.

Parameter	Value
Sensor	APS-C type CMOS sensor
Focal length (mm)	16
Sensor width (mm)	23.5
Sensor length (mm)	15.6
Effective pixels (megapixels)	16.7
Pixel size (micrometers)	4.82
ISO sensitivity range	100–3200
Image format	RAW (Sony ARW 2.2 format)
Weight (g)	269

By removing the internal infrared filter from the Sony NEX-5N camera, the sensitivity of the sensor was enhanced to encompass specific regions of the electromagnetic spectrum, including the near-infrared (820 nm) and ultraviolet (390 nm) wavelengths. The spectral responsiveness of this modified camera is shown in Figure 1b. Notably, the modified sensor exhibits sensitivity to distinct segments of the electromagnetic spectrum in contrast to its unmodified counterpart, the Sony NEX-7, which retains the internal infrared filter (as illustrated in Figure 1a) [55]. This modified camera was equipped with a collection of filters to obtain data corresponding to ultraviolet (UV) and near-infrared (NIR) spectral bands. The transmission curves of the filters employed during the data acquisition process are shown in Figures 2 and 3.

- The terrestrial laser scanner employed in this study was the Faro Focus S350 laser scanner, developed by Faro Technologies (Lake Mary, FL, USA). It has proven to be an invaluable tool for archaeological and building studies applications. Its cutting-edge phase-based laser scanning technology enables it to accurately measure distances and efficiently gather an extensive dataset of millions of data points in a short span. Particularly relevant in archaeological studies, this scanner aids in documenting historical

sites and structures with high precision. The Faro Focus S350 laser beam wavelength is 1550 nm (Table 3). This allowed us to obtain building spectral information in the short-wavelength infrared spectral (SWIR) band [56]. Concerning the use of data derived from the laser scanner, the registered return signal intensity value has been used as its application has been demonstrated to be effective in buildings made of stone [22].

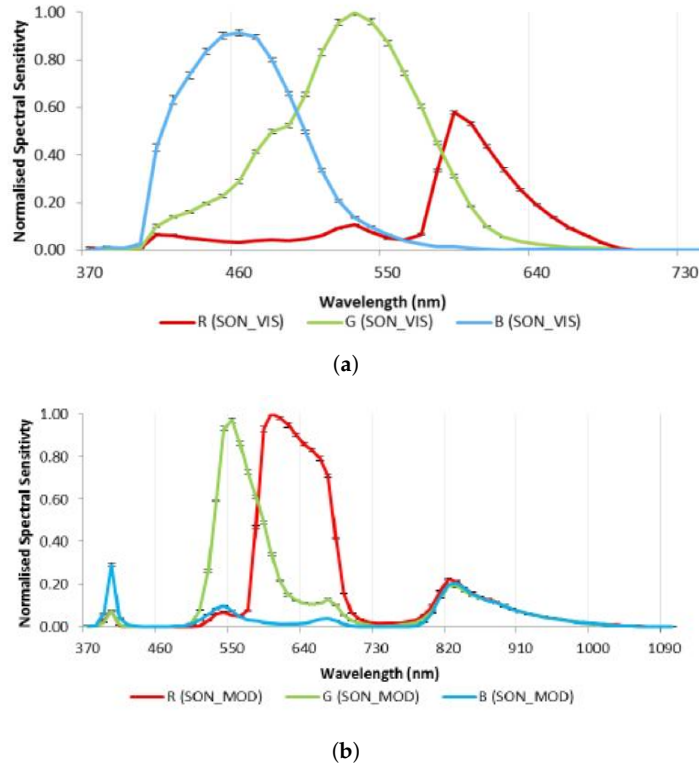


Figure 1. Spectral responses for Sony NEX cameras, from [55]: (a) Unmodified camera, normalized to the peak of the green channel. (b) Modified camera, normalized to the peak of the red channel.


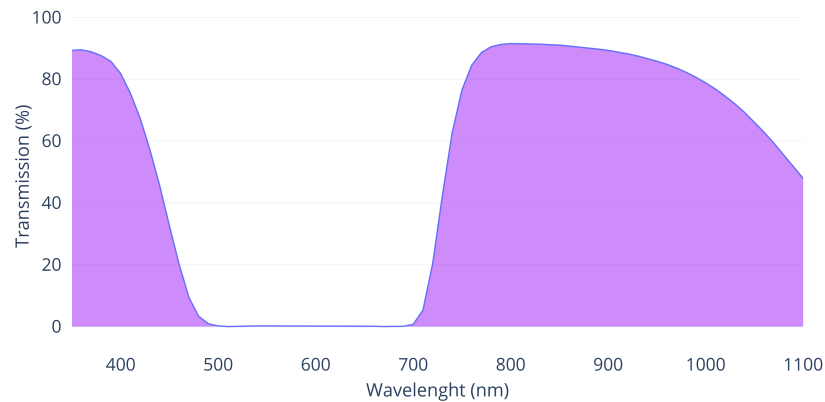


Figure 2. Midopt DB 660/850 Dual Bandpass filter light transmission curve (Midwest Optical Systems, Inc., Palatine, IL, USA).



**Figure 3.** ZB2 filter light transmission curve, from Shijiazhuang Tangsinuo Optoelectronic Technology Co., Ltd., Shijiazhuang, Hebei, China.

- For data collection in the upper regions of the building, where ground-based sensors lack access, an Unmanned Aerial Vehicle (UAV) was deployed. The chosen instrument was the Parrot Anafi Thermal (Table 4), which mounts a dual-camera system comprising an RGB sensor (for the visible spectrum) and an infrared thermal sensor. This configuration facilitates the simultaneous capture of conventional RGB and infrared thermal images within a single flight mission. Referring to the thermal infrared data, the Parrot Anafi Thermal incorporates a factory-calibrated uncooled microbolometer-type FLIR Lepton 3.5 thermal module [57], enabling the establishment of an absolute temperature for each image pixel. Consequently, precise surface temperatures of the building points were determined. This aids in discerning the discontinuities and potential pathologies resulting from the heterogeneity of construction materials [19].

**Table 3.** Faro Focus S 350 Laser Scanner sensor parameters.

Parameter	Value
Range	0.6–350 m
Angular FOV (vertical)	300°
Angular FOV (horizontal)	360°
Beam Divergence	0.3 mrad
Beam Diameter at Exit	2.12 mm
Laser Wavelength	1550 nm

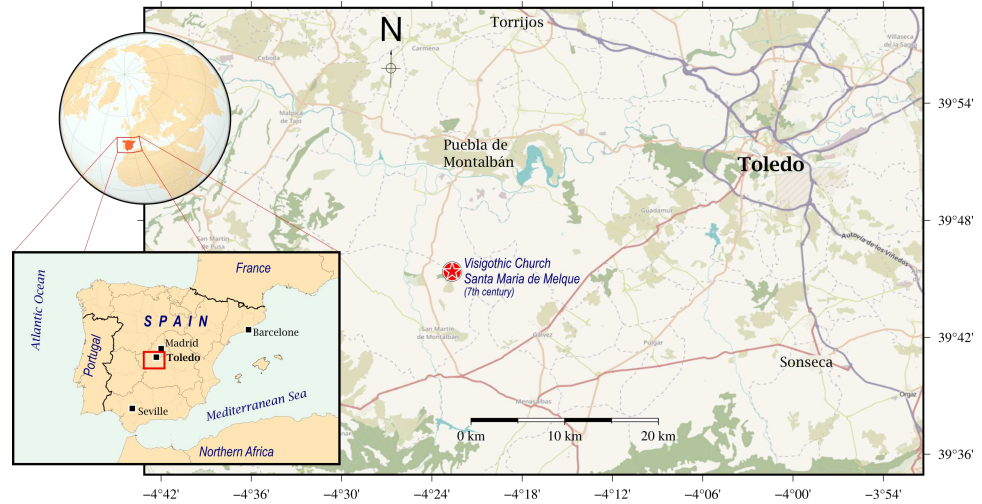
**Table 4.** Parrot Anafi Thermal sensor parameters.

Parameter	Value
Thermal sensor spectral range	8 $\mu\text{m}$ –14 $\mu\text{m}$
Thermal sensor size	160 $\times$ 120 pixels
Pixel pitch	12 $\mu\text{m}$
Thermal Sensitivity	0.050 °C

## 2.2. Data Capture Campaign

For data acquisition, an emblematic building of Spanish historical heritage was selected. The chosen structure was the Visigothic Church of the Santa Maria de Melque. Data from all the described sensors were directly collected on this 7th-century A.D. building [58], located in the province of Toledo, Spain. The archaeological complex of Santa Maria de Melque (N 39.750878°, W 4.372965°) is located approximately 30 km southwest of the city of Toledo, in close proximity to the Tagus River [59] (Figure 4).

The structure of the Visigothic church of Santa Maria de Melque was constructed using masonry of immense granite blocks assembled without mortar, distinguished by its barrel vault covering the central nave. The layout of the aisles in the form of a Greek cross, the straight apse, and the arrangement of architectural elements reveal both Roman and Byzantine influences, reflecting the rich cultural diversity of the period [60].



**Figure 4.** Location of the building surveyed.

The data collection campaign was carried out only on the exterior of this building in February 2022. The campaign covered the entire architectural structure and its ornamental elements. This location was chosen for its historical and architectural relevance, which allowed us to obtain precise and detailed information on the current state of the building and its possible pathologies. Figure 5 shows the studied building.



**Figure 5.** Visigothic Church of Santa Maria de Melque, seen from the southeast.

Prior to capturing the dataset, a meticulous preparatory phase was undertaken, involving the careful placement of a series of precision targets across the walls surface. These identified markers collectively formed a robust set of control points that served as pivotal

anchors for the subsequent data collection process. By ensuring uniformity and accuracy at these measurement points, a reliable common geometric reference system was established, effectively standardizing the subsequent data acquisition process across all data collection sessions. This rigorous methodology not only underscored the accuracy of the data collected but also facilitated seamless comparability and analysis of the collected visual information (Figure 6).



**Figure 6.** Target signals attached to walls and on terrain.

The Terrain Target Signals (TTS) were measured using GNSS techniques. These marks were materialized by means of a metal nail in the ground, in order to be revisited on future occasions. Subsequently, a flat black-and-white square sign measuring 30 cm on each side was adopted (Figure 6).

For the observation, dual-frequency Topcon Hiper GNSS receivers were used, with calibrated antennas (GPS, GLONASS), tripod and centering system on the point mark, measuring a total of 12 TTS, forming a network of 30 vectors. The observation time at each point was 15–20 min, with at least a double observation session at each point with different receivers, thus configured in relative static surveying with high repeatability.

In the subsequent processing of GNSS data, to obtain greater precision in the results, the precise geodetic correction models of the ionosphere from the CODE (Center for Orbit Determination in Europe) and precise ephemeris from the IGS (International GNSS Service) for both constellations were downloaded. Along with these Topcon field GNSS data, data from continuous CORS (Continuously Operating Reference Stations) of the Spanish National Positioning System ERGNSS-IGN (Instituto Geográfico Nacional) were also processed. This was done in order to link the local GNSS measurements to a geodetic reference frame that guaranteed high precision stability and temporal permanence for future actions in the environment.

To compute the GNSS vectors, the Leica Infinity version 3.0.1 software was used, using the absolute antenna calibration models and using the VMF (Vienna Mapping Functions) [61]. Both for the observation and for the adjustment and compensation of the coordinates of all the TTS points that make up the network, the same methodology used in the implementation of geodetic precision control networks in engineering was followed [62]. The final adjustment of the network, the calculation of the coordinates and the estimation of its accuracy (Table 5) was performed with Geolab version px5 software, with a complete constraint in the ETRS89 (ETRF2000) frame.

Wall Surface Signals (WSS) were placed around the entire building and attached to the wall. They are intended to tie points supporting the georeferencing process in all point

clouds. WSS were 12 bit coded precision targets (Figure 7). Thus, each WSS can be clearly identified by photogrammetry software, almost in automatic mode, and operators.

In Figure 8, we show the distribution of targets on terrain (TTS) and on the walls (WSS). The coordinates of the precision targets attached to the walls (Wall Surface Signals) are expressed in Table A1.




Figure 7. Example of four 12 bit coded precision targets used as Wall Surface Signal (WSS).




Figure 8. Distribution of control points.

Table 5. Terrain Target Signals (TTS) coordinates and their standard deviations. UTM 30N coordinate system, ETRS89 (ETRF2000) geodetic frame. All values in meters.

Station	UTM 30 Coordinates		Height	Standard Deviations		
	Northing	Easting		North	East	Height
D001	4401021.383	382387.421	567.625	0.004	0.004	0.009
D002	4401007.299	382397.872	566.853	0.002	0.002	0.004
D003	4401011.239	382391.663	566.584	0.021	0.015	0.054

**Table 5.** *Cont.*

Station	UTM 30 Coordinates		Height	Standard Deviations		
	Northing	Easting		North	East	Height
D004	4400996.864	382365.065	568.053	0.003	0.002	0.006
D005	4401011.720	382359.282	568.848	0.003	0.003	0.007
D006	4401021.414	382377.979	565.803	0.014	0.005	0.017
D007	4401014.232	382362.130	567.291	0.007	0.005	0.012
D008	4401021.499	382383.108	565.844	0.010	0.005	0.014
D009	4400998.691	382375.501	567.076	0.007	0.005	0.013
D010	4400990.703	382374.625	568.205	0.002	0.002	0.005
D011	4401024.085	382363.273	567.641	0.005	0.004	0.009
D012	4401028.664	382375.382	566.752	0.006	0.004	0.011

### 2.3. Point Clouds

In the course of this research, a range of sensors were used for the collection of geomatic data across multiple spectral bands. The processing of each dataset has been carried out with great care, resulting in the generation of several georeferenced three-dimensional point clouds. These point clouds offer a comprehensive and diverse view of the building under examination from various angles (as presented in Table 6). Each point cloud, except the laser scanner point cloud, comes from a photogrammetric process. The photogrammetric software used was Agisoft Metashape version 1.8.5. All derived photogrammetry point clouds are the result of processing a single sensor in a single process. Only in RGB point cloud, unmodified terrestrial RGB camera and UAV RGB image datasets were combined in the same process to obtain the RGB point cloud.

Figure 9 illustrates a subset of the point clouds views resulting from the use of the aforementioned sensors. First, Figure 9a presents a visualization of the point cloud obtained via RGB sensors using both conventional terrestrial and aerial (UAV) cameras. This representation unveils architectural details as well as visible features perceptible to the naked eye, furnishing a meticulous view of the surface of the structure. This point cloud has been selected as the starting point for the development of the voxelized data structure of the building in question, which will be subjected to analysis in subsequent stages.

**Table 6.** Point Clouds.


Band	Number of Points
Red, Green and Blue (visible spectrum)	46,512,981
Near infrared	39,472,866
Ultraviolet	352,900,707
Short-Wavelength Infrared (Laser Scanner)	54,735,907
Thermal infrared	6,412,099

Figure 9b shows the point cloud corresponding to the UV spectral band. This view allowed us to identify elements that are typically imperceptible within the visible range. In this Figure 9b we also can see that not the entire building has point cloud information in this band.

Finally, in Figure 9c,d, we depict the point cloud generated by our infrared thermal sensor. This visual representations highlight the heat distribution on the building surface, endowing us with an exceptional perspective concerning potential issues related to heat retention and the variability of construction materials.

Beyond the previously outlined difficulties concerning data structure, heterogeneity, and inconsistent density, point clouds generated by multiple sensors emanate from disparate data origins and convey unique informational facets. Consequently, it becomes essential to formulate strategies for the fusion of both geometric and spectral elements with

the aim of optimizing data processing and extracting valuable conclusions from the varied information contained within.



**Figure 9.** Different point clouds obtained from data acquisition campaign.

#### 2.4. Voxelization

To facilitate an optimal analysis, it is necessary to fuse the numerous point clouds that have been generated. To accomplish this, we have employed voxels as the data structure, specifically the multispectral voxel variant developed in our previous research [29].

Voxels, abbreviated from “volumetric elements”, serve as the fundamental abstract units in three-dimensional space, each having predetermined volume, positional coordinates, and attributes [63]. They offer significant utility in providing topologically explicit representations of point clouds, thereby augmenting the informational content.

In this study, we examined how the selected elemental voxel size affects the point distribution within the point clouds. Voxel structures with various elemental sizes (50, 25, 10, 5, and 3 cm) were created. To manage the point clouds and their voxelization, we used the Open3d open-source library [64]. We used the RGB point cloud as the initial dataset to create voxel structures, given its comprehensive coverage of the entire building. After establishing voxel structures based on these sizes, we located the points from each respective cloud enclosed within individual voxels. In instances where one specific voxel enclosed multiple points from a particular spectral band, the voxel’s spectral property was set to the mean value of those enclosed points. Additional statistical metrics, such as the maximum, minimum, and variance values, were also calculated. Given that the voxel

adopts the spectral attributes of enveloped points, it effectively becomes a multispectral voxel [29]. The concept of a multispectral voxel used in this work is illustrated in Figure 10.

Figure 11 illustrates how point clouds are distributed along the 5 cm elemental voxel structure. For other chosen voxel elemental sizes, please refer to Appendix A, where we provide the respective distributions. The histograms in Figure 11 show the number of points per voxel in each spectral band.

We have also carried out an analysis of the influence of the size of the elementary voxel with respect to the number of points contained. We can observe their distribution in the form of histograms in Figure 12. We note that the distribution of the spectral bands contained in the multispectral voxels does not depend specifically on the elemental voxel size, as the distributions outlines are similar.




Figure 10. Multispectral voxel concept.

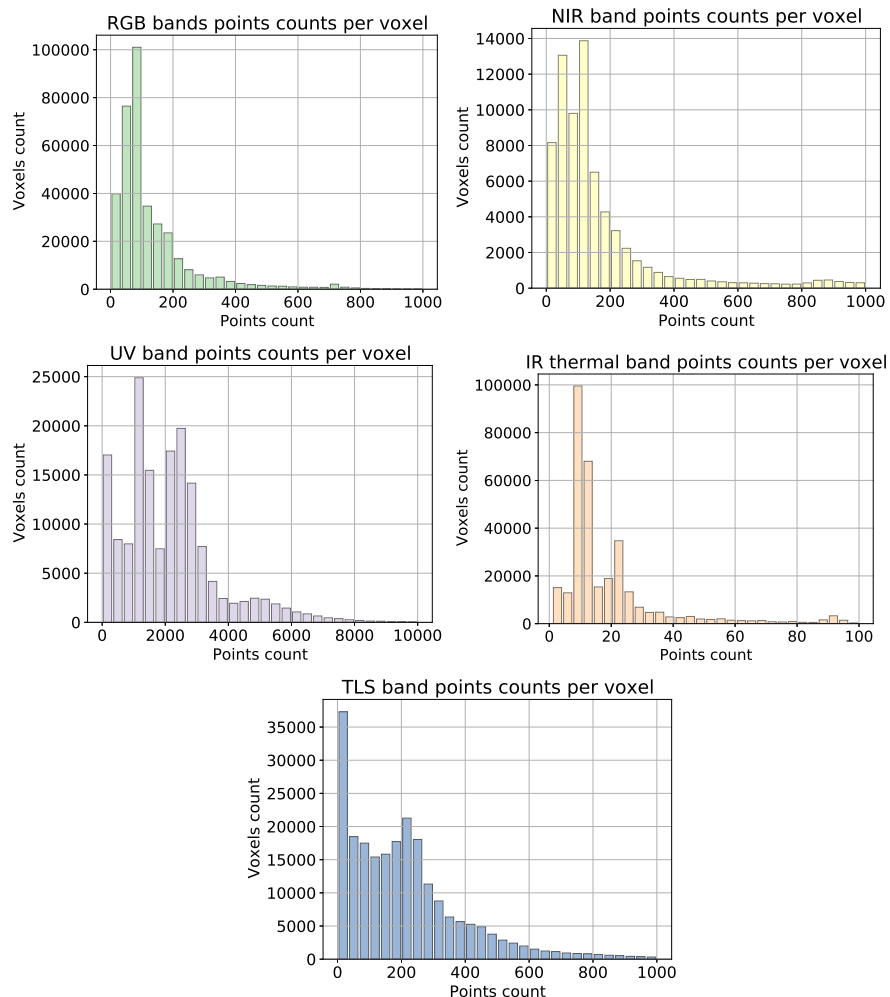
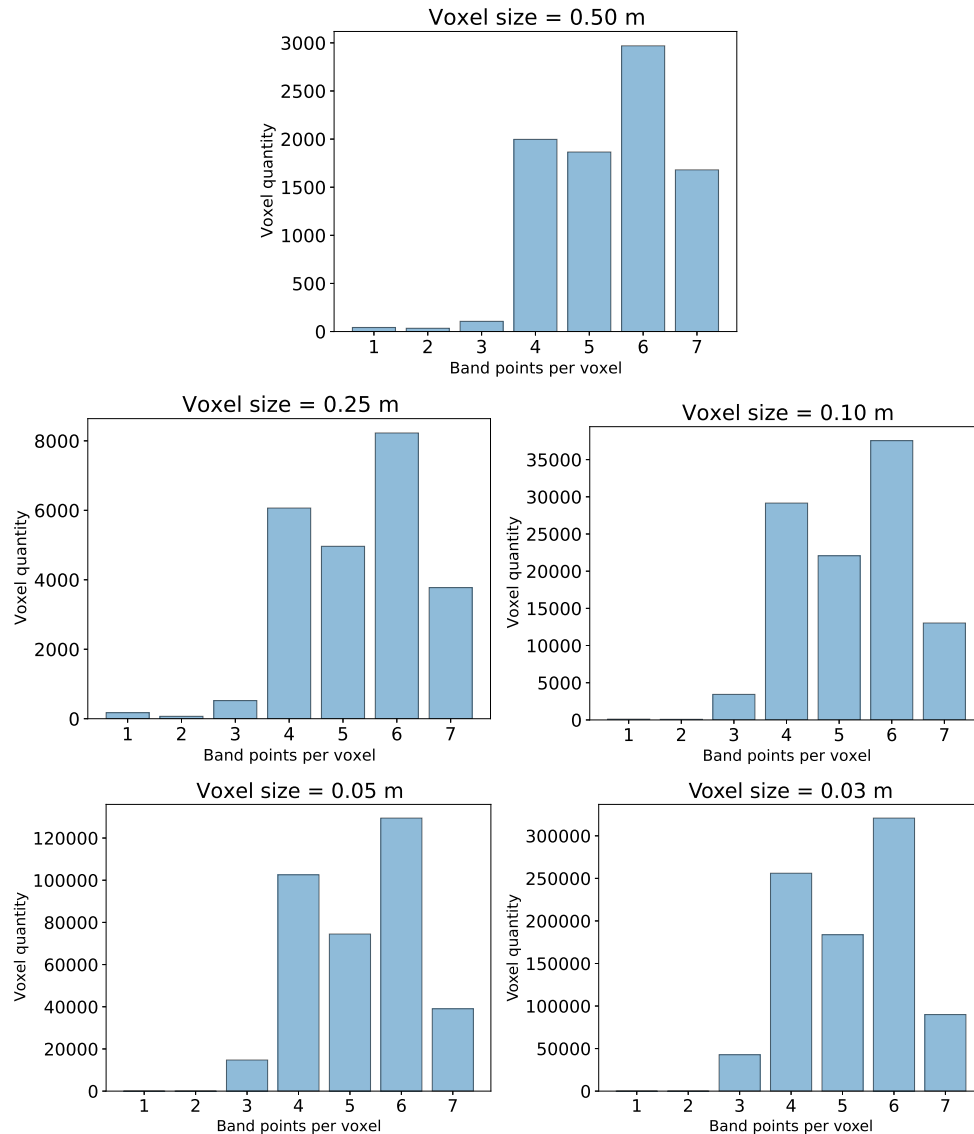


Figure 11. Number of Points per 5 cm Voxel.

Once the structure of multispectral voxels is established, it is crucial to process this data to gain insights and draw conclusions about the target building under study. In this research work, we have opted for the implementation of Self-Organizing Maps (SOMs) algorithms, due to their multiple advantages in handling voxel data. SOMs provide an efficient summarization of data, facilitating understanding, especially when dealing with large datasets, thus excelling in dimensionality reduction tasks. They do not require a separate training phase and are adept at exploiting spatial attributes while maintaining local neighbourhood relationships. With a design that is more intuitive than other neural network types, SOMs ease the interpretation of generated outcomes, making them particularly suitable for tackling categorization problems.



**Figure 12.** Distribution of various spectral bands according to different voxel elemental sizes.

### 2.5. Self-Organizing Maps


The Self-Organizing Map (SOM) executes a transformation from an input space of higher dimensionality to a map space of lower dimensionality, using a two-layered, fully interconnected neural architecture. The input layer comprises a linear array of neurons and the elementary units of an Artificial Neural Network (ANN), and the number of these

neurons corresponds to the dimensionality of the input data vector ( $n$ ). The output layer, also known as the Kohonen layer, is composed of neurons, each possessing a weight vector that matches the dimensionality of the input data ( $n$ ). These neurons are organized within a rectangular grid of arbitrary dimensions ( $k$ ). The weight vectors are collectively represented in a weight matrix configured as an  $n \times k \times k$  array [65]. Figure 13 illustrates the typical Kohonen map architecture.

Among the various features provided by the use of SOMs are the following:

- Group together similar items and separate dissimilar items.
- Classify new data items using the known classes and groups.
- Find unusual co-occurring associations of attribute values among items.
- Predict a numeric attribute value.
- Identify linkages between data items based on features shared in common.
- Organize information based on relationships among key data descriptors.

It has been proven that SOMs need complete data records [66]. SOMs are highly sensitive to Nan values and empty fields in the input layer. For this purpose, only full voxels, that is, those with at least one point contained in each of the point clouds to be fused, were classified in our training.



**Figure 13.** Typical Kohonen map architecture (source: [65]).

#### SOM Quality Indices

The various parameters that define a SOM can lead to different neural spaces. SOM quality measures are required to optimize training, such that meaningful conclusions can be drawn from them. Among these, the most significant quality indices are:

- Quantization error is the average error made by projecting data on the SOM, as measured by euclidean distance, i.e., the mean euclidean distance between a data sample and its best-matching unit [67]. Best value of quantization error is zero.
- Topographic product (TP) [68] measures the preservation of neighborhood relations between input space and the map. It depends only on the prototype vectors and map topology, and can indicate whether the dimension of the map is appropriate for fitting the dataset, or if it introduces neighborhood violations, induced by foldings of the map [67]. Topographic product will be  $<0$  if map size is small and  $>0$  if map size is big. Best value will be the one with the lower absolute value.

In this work, SOM quality indices have been calculated using an open-source library, SOMperf [67].

To determine the optimal neuron map size ( $k$ ), Topographic Product (TP) [68] has been used. An approximation corresponding to a rule of thumb, according to Equation (1):

$$k = 5\sqrt{N}, \tag{1}$$

being  $N$  the number of full voxels in the voxelized structure.

In Figure 14 we summarize in a flowchart the handling of the processed data during our multisensor data fusion strategy.




Figure 14. Multisensor data fusion with multispectral voxels and SOM flowchart.

### 3. Results

SOM trainings was performed for each voxel size. For this purpose, the optimal map size was determined such that the topographic product was minimum (in absolute value). Table 7 lists the different parameters according to the voxel size, as well as the obtained topographic product and quantization error.

Table 7. SOM map sizes.

Voxel Size (m)	Num. Voxels	Num. Full Voxels	% Full Voxels	Map Size by Equation (1)	Optimal Map Size	TP (abs) $\times 10^{-4}$	Quantization Error
0.50	8743	1681	19.22	8	17	0.49	0.161
0.25	23,962	3775	15.75	17	20	0.37	0.148
0.10	105,552	13,038	12.35	24	30	21.33	0.127
0.05	360,371	39,052	10.83	32	34	8.17	0.118
0.03	893,448	89,954	10.06	38	32	6.51	0.123

One of the first steps prior to training is the normalization of the data. Normalization helps the features to have a similar scale, facilitating the training process and faster convergence. In addition, normalization helps to avoid problems associated with large gradients during training, which negatively affect model convergence. In our work, we conducted a Min-max rescale normalization.

To illustrate, we will concentrate on the presentation of the SOM outcomes for a voxel size of 5 cm (0.05 m). The varied results of the maps according to the voxel size are organized in Appendix A.

As shown in Figure 13, the results of the training and classification of a self-organized map are provided by a matrix of neurons, which are assigned a series of weights given by the input layer. One way to show the relationships between neurons is to express the distances between them (Figure 15). The lighter parts in that matrix represent the parts of the map where the nodes are far away from each other, and the dark parts represent less distance between nodes.




Figure 15. U-Matrix SOM voxel 0.05 m.

Each activated neuron represents a set of voxels. There are also neurons that have not been activated by any of the vectors given by the multispectral voxels within the input layer. Figure 16 shows how many patterns (*x*-axis) have been recognized by how many neurons (*y*-axis).




Figure 16. Activated neurons from SOM voxel 0.05 m.


The distribution of activations can be seen in the activation map depicted in Figure 17.




Figure 17. Heatmap of activated neurons from SOM voxel 0.05 m.

In the same way, we show how the activations of the neurons are distributed within each codebook vector (Figure 18).


Red




Green



Blue



NIR



UV




Figure 18. Cont.

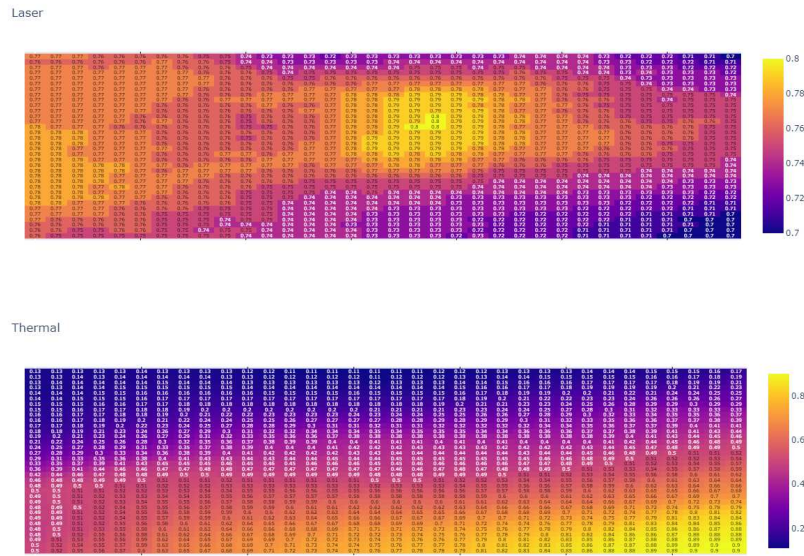


Figure 18. SOM codebooks for voxel 5 cm.

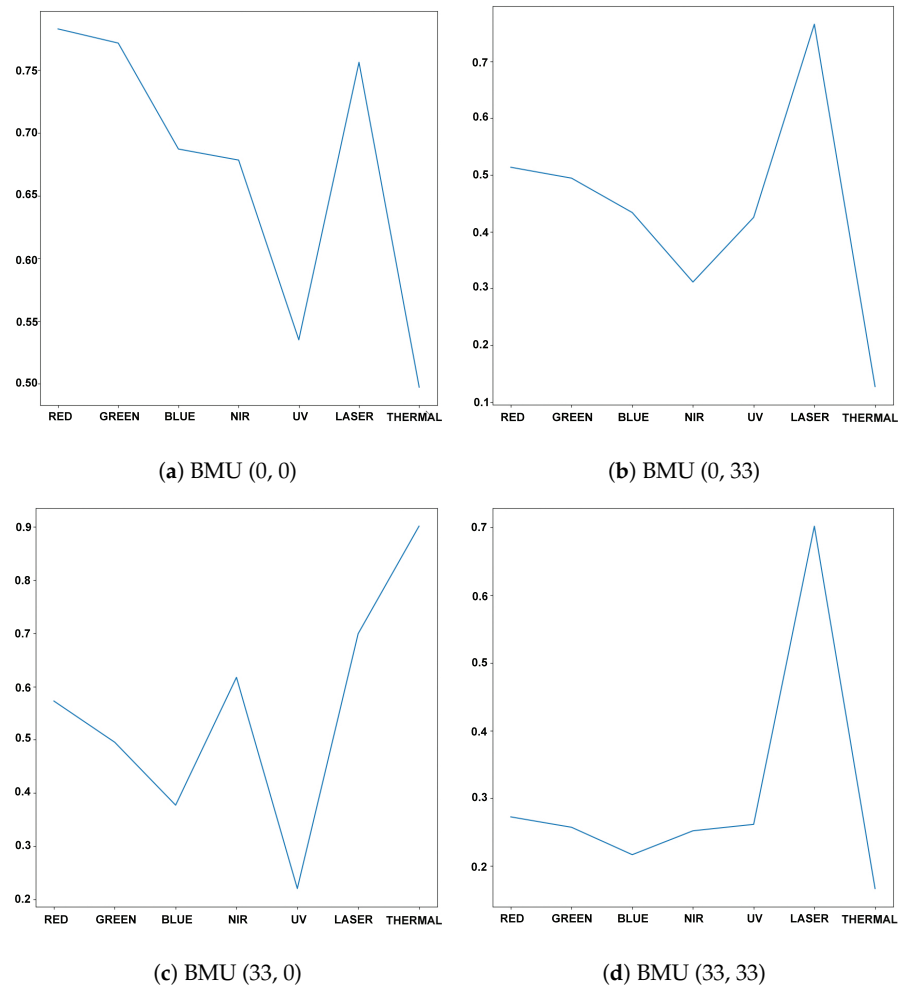
4. Discussion

The use of Self-Organizing Maps (SOM) for the training and classification of multi-spectral voxel structures results in the generation of a neural map. In this map, each neuron points towards a group of voxels that exhibit similar characteristics, as indicated by a vector of weights assigned to each property (spectral band) of the input layer. Every voxel in the input layer has a Best Machine Unit (BMU). The BMU is the neuron whose weight vector is closest in the space to the pattern.

In the SOM heat map voxel 5 cm (Figure 17), we can identify which neurons are those that determine clearer patterns because they have been activated a greater number of times. We highlight the neurons in the corners of the heat map.

- Neuron (0, 0), activated by 274 voxels. The red band is the predominant band, together with the laser. The UV and thermal bands have less weight for these voxels (Figure 19a). These activated voxels are mostly located on the south building façade.
- Neuron (0, 33), activated by 425 voxels. Its most important band is the laser band. The rest of the bands (RGB and UV) show a medium weight, whereas the thermal information has little influence (Figure 19b). Its voxels are located on the western planes not illuminated by the Sun during data acquisition.
- Neuron (33, 0), activated by 621 voxels. Its characteristic band is the thermal band, with a minimum in the UV band. The red and green bands, along with the NIR have medium weights. The laser band also has considerable weight (Figure 19c). The voxels targeted by this neuron are located on the northern façade.
- Neuron (33, 33), activated by 136 voxels. Larger weight of the laser band. The rest of the bands (RGB, NIR, UV, and thermal) have lower weights (Figure 19d).

However, each neuron does not act in isolation, but interconnects with nearby neurons (Figure 15). Nearby neurons interrelate similar multispectral voxels. As shown in Figure 18, neurons can be zoned using cross-band interrelated weights. In our analysis, we have observed a striking similarity in the distribution of weights of the neurons in the heatmap, corresponding to the red, green, and blue bands, located in the lower left corner. This finding can be attributed to the fact that the built-up area of the building, as depicted in Figure 5, primarily exhibits a red-grayish tone, derived from the granite construction.



**Figure 19.** Characteristic Graph on some neurons of SOM voxel 5 cm.

This distribution of weights presents an opportunity for further analysis. Employing a clustering algorithm, as the K-means method, we have successfully segmented the BMUs. Using, for example, a 12-zone clustering, we are able to identify similar BMUs in a manner that considerably streamlines analysis and enhances decision-making (Figure 20).

The primary focus of our methodology is to identify and study building pathologies through the fusion of geomatic sensor data. We identified an area with dampness in the building that was examined. This area is located in the lower part of one of the northern façades (Figure 21). Dampness in buildings can lead to various issues such as the formation of salt efflorescence. These are white deposits on the surfaces resulting from the migration of soluble salts in water through the pores of the construction materials. This phenomenon often occurs when water carries salts from the ground to walls. In addition to efflorescence, moisture can trigger mold growth, material deterioration, and structural problems [69].

In order to evaluate our hypothesis regarding the potential application of multispectral voxels in multisensor data fusion for the purpose of studying building pathologies through the use of self-organizing maps (SOMs), we specifically focused on the voxels that represented areas of the building with pathology present. We then identified the best matching units (BMUs) for these voxels and discovered that they were located in close proximity to the neuron (33, 20). To confirm the validity of their weight vector, we obtained the corresponding characteristic graph, shown in Figure 22. The graph indicates a strong correlation between the visible spectrum bands and the laser scanner band.





Figure 20. Clustering of BMU Hits Matrix by K-means algorithm (12 clusters).



Figure 21. Pathology in north façade of the building.

Earlier research in remote sensing building pathologies studies discovered that the infrared spectral range, particularly the 778, 905, and 1550 nm wavelength bands, is ideal for detecting dampness. The study [1] found that the best results were obtained using short-wave infrared data (1550 nm). Visible wave bands can detect efflorescence, as surfaces with this phenomenon have higher reflectance in these spectral ranges. For chlorides or sulphates being the cause, the short-wave infrared range is more appropriate. In accordance with the research conducted by [1], our methodology demonstrates a higher level of effectiveness as it does not rely on the derivation of information from point clouds to images to localize and study pathologies. Instead, we work directly with the original 3D point clouds, integrating geospatial 3D geometry with multispectral data information.



**Figure 22.** Characteristic graph of BMU (33, 20).

## 5. Conclusions

Given the vast amount of data provided by different geomatic sensors and the diverse nature of the information they offer, it is challenging to manage multisensor data and generate knowledge from it. Therefore, new approaches are required to effectively and efficiently express this information from these sensors. Our methodology combines the power of voxels in their multispectral character, which is necessary for data fusion, with deep-learning algorithms. In this case, the methodology was tested in a study of a cultural heritage building. Using this methodology, we were able to geospatially locate areas (through their respective voxels) that exhibit certain characteristics, showing pathologies. This allows to identify, study, and derive information from them about any building that has been studied with different sensors, regardless of their nature. Our methodology provides a powerful tool for analyzing architectural structures using various sensors fusing their data. The use of multisensor multispectral voxels locates possible pathologies such as damp and efflorescence in buildings. Further studies can verify correlations between the SOM and different fused sensors, defining their characteristic curves in such a way as to identify the whole catalogue of the most common pathologies in Historical Heritage buildings.

**Author Contributions:** All authors have made significant contributions to this manuscript. Conceptualization, J.R., S.L.-C.M., T.R.H.-T. and E.P.-d.-I.-S.; methodology, J.R.; software, J.R.; validation, J.R.; formal analysis, J.R., S.L.-C.M. and T.R.H.-T.; investigation, J.R.; field observations: J.R., S.L.-C.M., J.A.d.M. and E.P.-d.-I.-S.; resources, J.R., S.L.-C.M., T.R.H.-T. and E.P.-d.-I.-S.; data curation, J.R. and S.L.-C.M.; writing—original draft preparation, J.R.; writing—review and editing, J.R., S.L.-C.M., J.A.d.M., T.R.H.-T. and E.P.-d.-I.-S.; supervision, S.L.-C.M., J.A.d.M., T.R.H.-T. and E.P.-d.-I.-S. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by Grupo Acre at Fundación Premio Arce reference FPA1900001501.

**Data Availability Statement:** The data presented in this study are available on request from the corresponding author.

**Acknowledgments:** We extend our gratitude to the dedicated staff of the Geovisualización, Espacios Singulares y Patrimonio (GESyP) research group. Additionally, the first author, Javier Raimundo, expresses his appreciation to the Consejo General de la Arquitectura Técnica de España (CGATE) for their valuable support. Special thanks to Noemi Martinez for her assistance in the field data capture campaign.

**Conflicts of Interest:** The authors declare no conflict of interest.

## Abbreviations

The following abbreviations are used in this manuscript:

TLS	Terrestrial Laser Scanner
NIR	Near Infrared
RGB	Red, green and blue
IR	Infrared
UV	Ultraviolet
TTS	Terrain Target Signals
WSS	Wall Surface Signals
GNSS	Global Navigation Satellite Systems
CODE	Center for Orbit Determination
IGS	International GNSS Service
CORS	Continuously Operating Reference Stations
IGN	Instituto Geografico Nacional
VMF	Vienna Mapping Functions
SOM	Self Organizing Map
ANN	Artificial Neural Network
SWIR	Short-Wavelength Infrared
TP	Topographic Product
BIM	Building Information Modelling
BMU	Best Matching Unit

## Appendix A

### Appendix A.1. Surface Targets Coordinates

Here, we show the coordinates for the signals attached on building surface (Table A1).

**Table A1.** Wall Surface Signals (WSS) coordinates. UTM 30N coordinate system, ETRS89 (ETRF2000) geodetic frame. All values in meters.

Target Signal	UTM 30 Coordinates		Height
	Northing	Easting	
target 1	382360.015	440005.730	567.466
target 2	382368.957	4401021.247	566.398
target 3	382387.272	4401026.984	567.755
target 4	382396.179	4400998.666	567.397
target 5	382360.322	4400996.444	568.799
target 6	382388.457	4401003.889	566.041
target 7	382379.653	4400999.527	567.669
target 10	382382.008	4401000.464	568.380
target 12	382385.244	4401004.683	568.189
target 13	382383.552	4401018.785	567.828
target 15	382385.290	4401017.194	566.884
target 16	382367.348	4401015.839	569.020
target 18	382385.407	4401002.420	566.875
target 20	382380.706	4401019.521	567.237
target 21	382378.862	4401018.659	566.457
target 25	382374.552	4401019.167	568.003
target 26	382363.300	4401013.857	569.381
target 27	382391.098	4401011.804	568.204
target 28	382366.036	4401007.650	569.078
target 29	382378.289	4400999.028	568.894
target 30	382363.924	4401014.202	568.630
target 34	382372.581	4401003.133	569.414
target 35	382382.719	4401020.449	567.849
target 36	382370.265	4401017.214	567.388
target 37	382370.390	4401002.189	568.604
target 43	382368.778	4401001.428	569.551
target 45	382388.164	4401010.347	568.259
target 47	382389.463	4401015.952	568.259
target 48	382390.180	4401014.380	568.103
target 50	382385.086	4401001.835	568.112

Appendix A.2. Points Histograms

In Appendix A.2, we present the distribution of points per voxel through histograms, based on the voxel's elemental size.

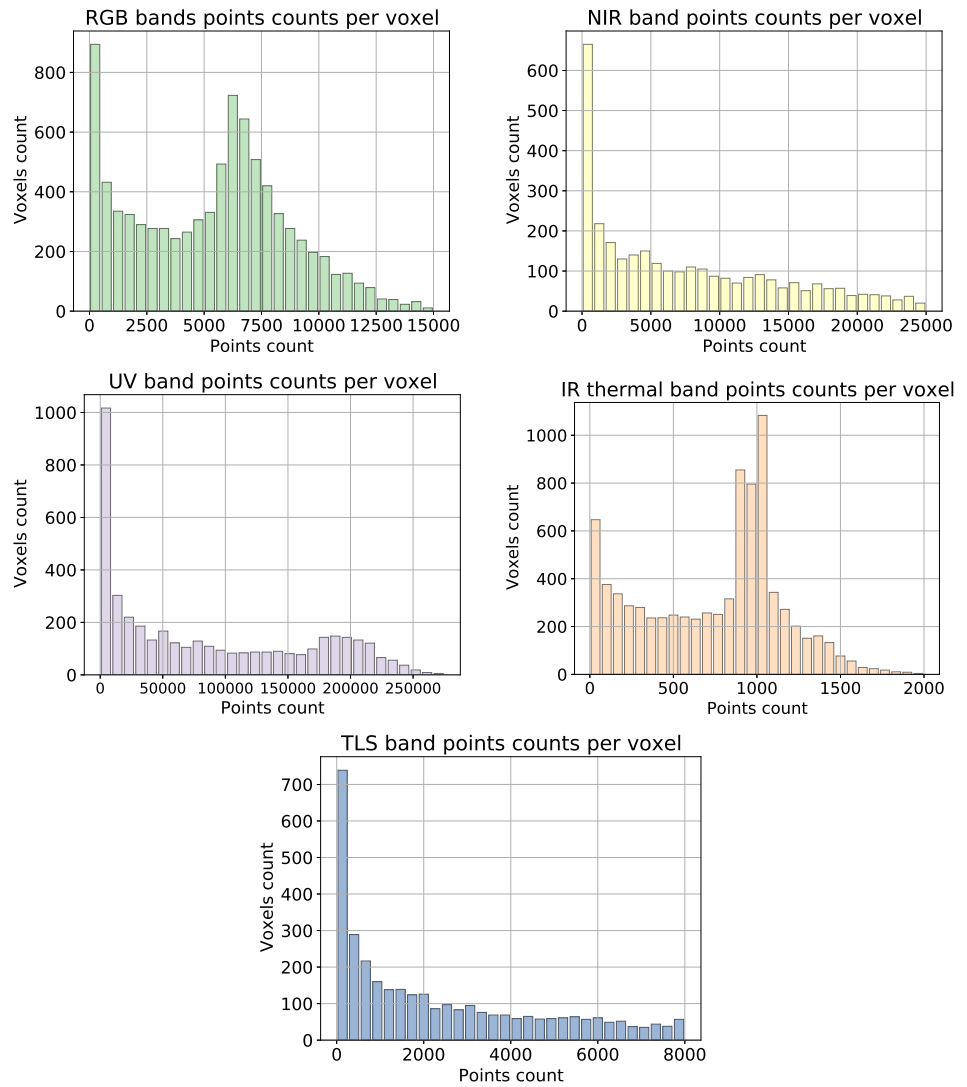


Figure A1. Points per voxel. Voxel size: 50 cm.

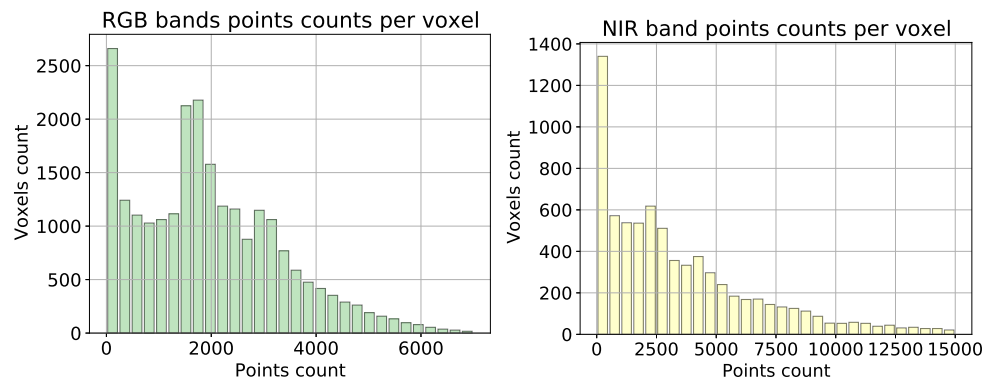


Figure A2. Cont.

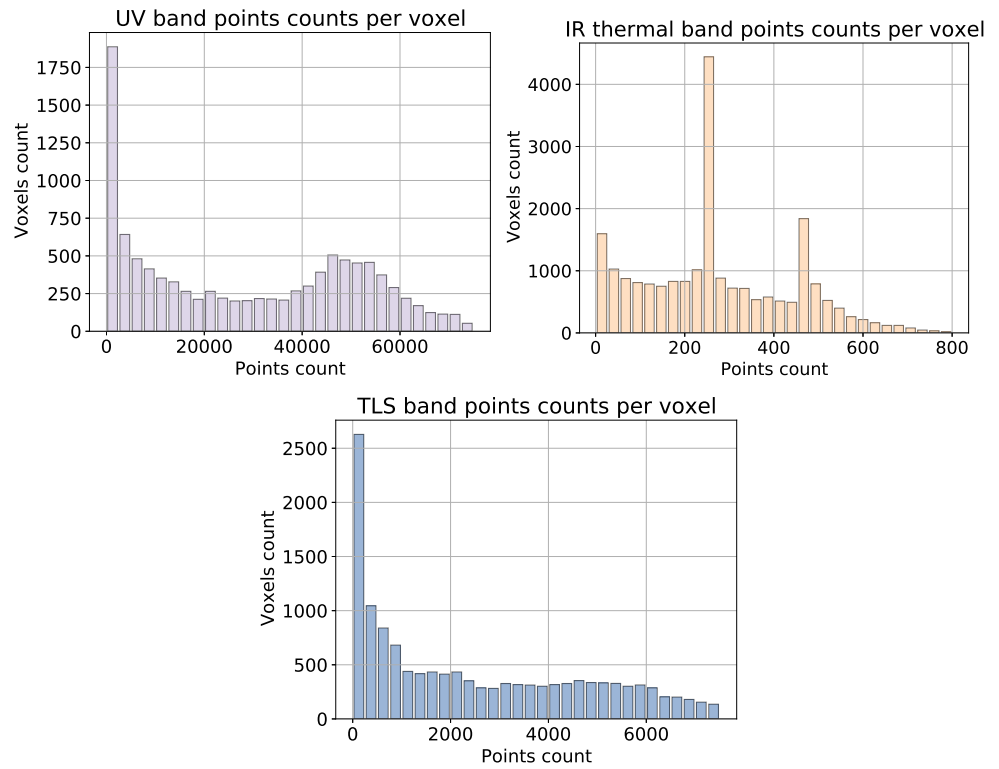


Figure A2. Points per voxel. Voxel size: 25 cm.

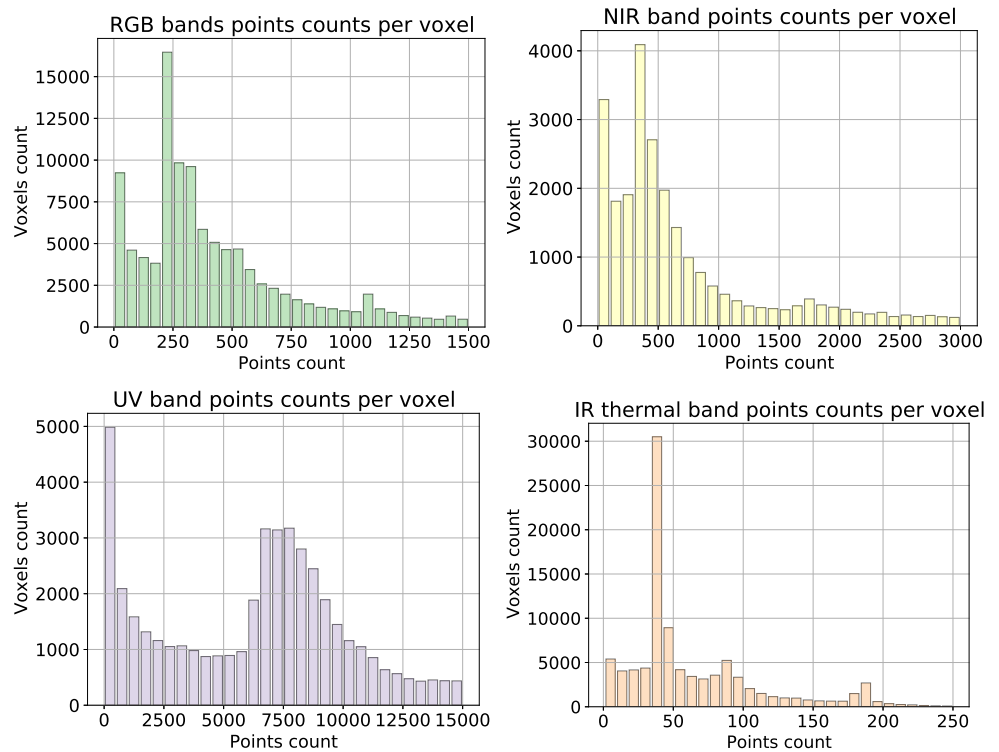


Figure A3. Cont.

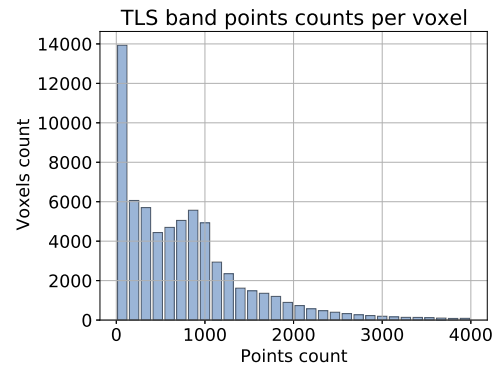


Figure A3. Points per voxel. Voxel size: 10 cm.

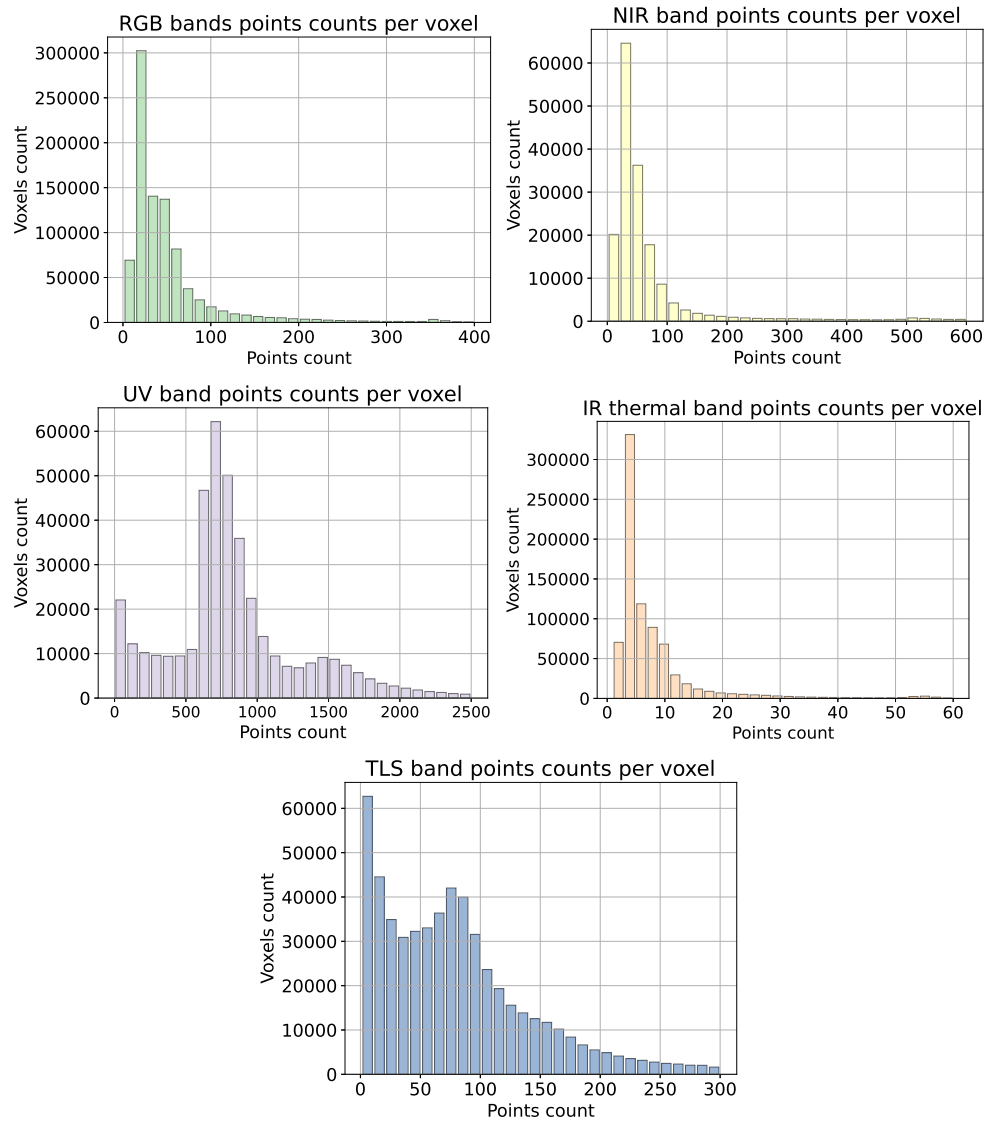
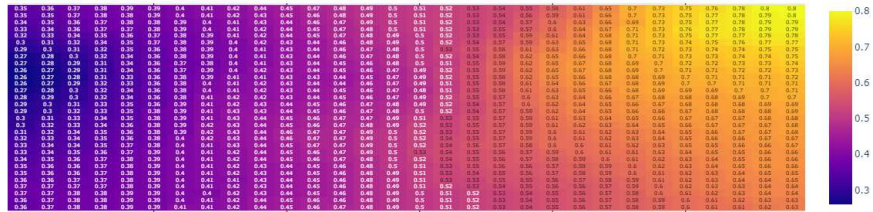


Figure A4. Points per voxel. Voxel size: 3 cm.

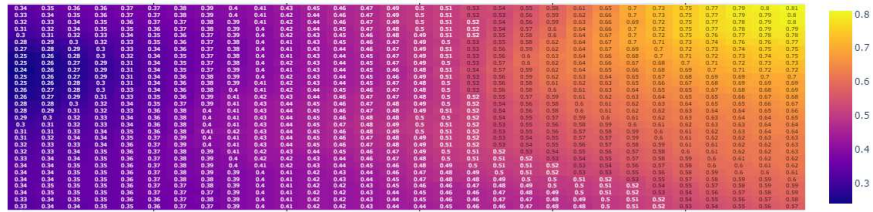
Appendix A.3. SOM Codebooks

Here, in Appendix A.3, we express the different heat map codebooks, which allows to see map distribution of all of its characteristics. Different voxel elemental sizes have been trained, expressing coherent results within the Results Section 3 and Discussion Section 4.

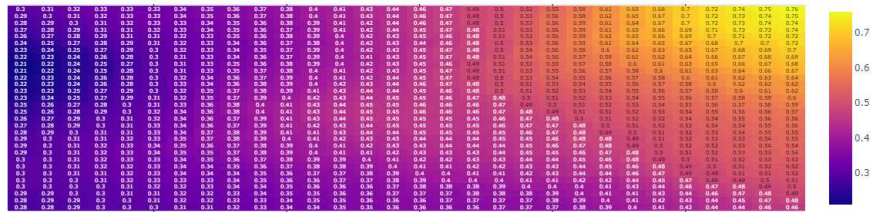
Red



Green



Blue



NIR






Figure A5. Cont.

UV



Laser



Thermal

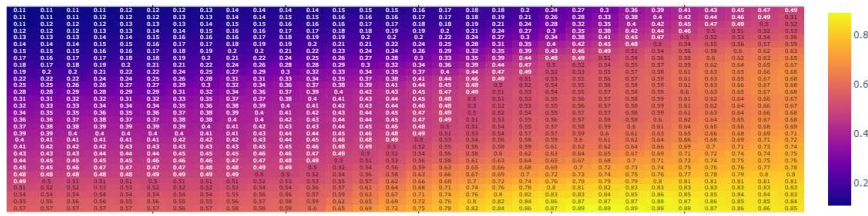



Figure A5. SOM codebooks for voxel 10 cm.

Red



Green

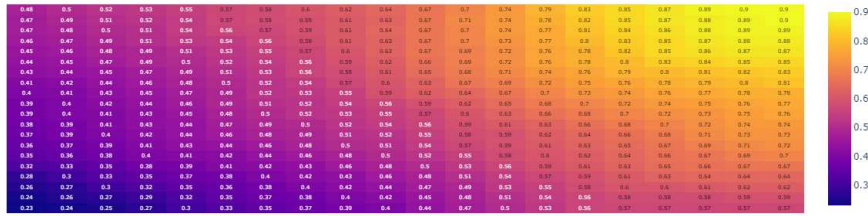




Figure A6. Cont.


Blue




NIR



UV



Laser



Thermal




Figure A6. SQM codebooks for voxel 25 cm.

## References

1. Del Pozo Aguilera, S. Multispectral Imaging for the Analysis of Materials and Pathologies in Civil Engineering, Constructions and Natural Spaces. Ph.D. Thesis, Universidad de Salamanca, Salamanca, Spain, 2016.
2. Torres-Martínez, J.A.; Sánchez-Aparicio, L.J.; Hernández-López, D.; González-Aguilera, D. Combining Geometrical and Radiometrical Features in the Evaluation of Rock Art Paintings. *Digit. Appl. Archaeol. Cult. Herit.* **2017**, *5*, 10–20. [[CrossRef](#)]
3. Crespo, C.; Armesto, J.; González-Aguilera, D.; Arias, P. Damage Detection on Historical Buildings Using Unsupervised Classification Techniques. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2010**, *38*, 184–188.
4. Moropoulou, A.; Labropoulos, K.C.; Delegou, E.T.; Karoglou, M.; Bakolas, A. Non-Destructive Techniques as a Tool for the Protection of Built Cultural Heritage. *Constr. Build. Mater.* **2013**, *48*, 1222–1239. [[CrossRef](#)]
5. Oreni, D.; Cuca, B.; Brumana, R. Three-Dimensional Virtual Models for Better Comprehension of Architectural Heritage Construction Techniques and Its Maintenance over Time. In *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*; Springer: Berlin/Heidelberg, Germany, 2012; Volume 7616 LNCS, pp. 533–542. [[CrossRef](#)]
6. Turco, M.L.; Mattone, M.; Rinaudo, F. Metric Survey and Bim Technologies to Record Decay Conditions. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2017**, *42*, 261–268. [[CrossRef](#)]
7. González-Jorge, H.; Lagüela, S.; Krelling, P.; Armesto, J.; Martínez-Sánchez, J. Single Image Rectification of Thermal Images for Geometric Studies in Façade Inspections. *Infrared Phys. Technol.* **2012**, *55*, 421–426. [[CrossRef](#)]
8. Dias, I.; Flores-Colen, I.; Silva, A. Critical Analysis about Emerging Technologies for Building's Façade Inspection. *Buildings* **2021**, *11*, 53. [[CrossRef](#)]
9. Masiero, A.; Costantino, D. TLS for detecting small damages on a building façade. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2019**, *XLII-2/W11*, 831–836. [[CrossRef](#)]
10. Kim, N.; Choi, Y.; Hwang, S.; Park, K.; Yoon, J.S.; Kweon, I.S. Geometrical Calibration of Multispectral Calibration. In Proceedings of the 2015 12th International Conference on Ubiquitous Robots and Ambient Intelligence, URAI 2015, Goyangi, Republic of Korea, 28–30 October 2015; pp. 384–385. [[CrossRef](#)]
11. Wang, Q.; Kim, M.K.; Sohn, H.; Cheng, J.C. Surface Flatness and Distortion Inspection of Precast Concrete Elements Using Laser Scanning Technology. *Smart Struct. Syst.* **2016**, *18*, 601–623. [[CrossRef](#)]
12. Wang, Q.; Kim, M.K.; Cheng, J.C.; Sohn, H. Automated Quality Assessment of Precast Concrete Elements with Geometry Irregularities Using Terrestrial Laser Scanning. *Autom. Constr.* **2016**, *68*, 170–182. [[CrossRef](#)]
13. Chiabrandio, F.; Lo Turco, M.; Rinaudo, F. Modeling the Decay in an Hbim Starting from 3d Point Clouds. A Followed Approach for Cultural Heritage Knowledge. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2017**, *42*, 605–612. [[CrossRef](#)]
14. Yaagoubi, R.; Miky, Y. Developing a Combined Light Detecting And Ranging (LiDAR) and Building Information Modeling (BIM) Approach for Documentation and Deformation Assessment of Historical Buildings. *MATEC Web Conf.* **2018**, *149*, 02011. [[CrossRef](#)]
15. Previtali, M.; Barazzetti, L.; Redaelli, V.; Scaioni, M.; Rosina, E. Rigorous Procedure for Mapping Thermal Infrared Images on Three-Dimensional Models of Building Façades. *J. Appl. Remote Sens.* **2013**, *7*, 073503. [[CrossRef](#)]
16. Lerma, C.; Mas, Á.; Gil, E.; Vercher, J.; Peñalver, M.J. Pathology of Building Materials in Historic Buildings. Relationship Between Laboratory Testing and Infrared Thermography. *Mater. Constr.* **2014**, *64*, e009. [[CrossRef](#)]
17. Mercuri, F.; Cicero, C.; Orazi, N.; Paoloni, S.; Marinelli, M.; Zammit, U. Infrared Thermography Applied to the Study of Cultural Heritage. *Int. J. Thermophys.* **2015**, *36*, 1189–1194. [[CrossRef](#)]
18. Sferra, S.; Marcucci, E.; Ambrosini, D.; Paoletti, D. Infrared Exploration of the Architectural Heritage: From Passive Infrared Thermography to Hybrid Infrared Thermography (HIRT) Approach. *Mater. Constr.* **2016**, *66*, e094. [[CrossRef](#)]
19. Luib, A. Infrared thermal imaging as a non-destructive investigation method for building archaeological purposes. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2019**, *42*, 695–702. [[CrossRef](#)]
20. Del Pozo, S.; Herrero-Pascual, J.; Felipe-García, B.; Hernández-López, D.; Rodríguez-González, P.; González-Aguilera, D. Multispectral Radiometric Analysis of Façades to Detect Pathologies from Active and Passive Remote Sensing. *Remote Sens.* **2016**, *8*, 80. [[CrossRef](#)]
21. Del Pozo, S.; Rodríguez-González, P.; Sánchez-Aparicio, L.J.; Muñoz-Nieto, A.; Hernández-López, D.; Felipe-García, B.; González-Aguilera, D. Multispectral Imaging in Cultural Heritage Conservation. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2017**, *42*, 155–162. [[CrossRef](#)]
22. Armesto-González, J.; Riveiro-Rodríguez, B.; González-Aguilera, D.; Rivas-Brea, M.T. Terrestrial Laser Scanning Intensity Data Applied to Damage Detection for Historical Buildings. *J. Archaeol. Sci.* **2010**, *37*, 3037–3047. [[CrossRef](#)]
23. Naranjo, J.M.; Parrilla, Á.; de Sanjosé, J.J. Geometric Characterization and Interactive 3D Visualization of Historical and Cultural Heritage in the Province of Cáceres (Spain). *Virtual Archaeol. Rev.* **2018**, *9*, 1–11. [[CrossRef](#)]
24. Antón, D.; Carretero-Ayuso, M.J.; Moyano-Campos, J.; Nieto-Julían, J.E. Laser Scanning Intensity Fingerprint: 3D Visualisation and Analysis of Building Surface Deficiencies. In *New Technologies in Building and Construction*; Bienvenido-Huertas, D., Moyano-Campos, J., Eds.; Springer Nature Singapore: Singapore, 2022; Volume 258, pp. 207–223. [[CrossRef](#)]
25. Batur, M.; Yilmaz, O.; Ozener, H. A Case Study of Deformation Measurements of Istanbul Land Walls via Terrestrial Laser Scanning. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *13*, 6362–6371. [[CrossRef](#)]

26. Bayarri, V.; Prada, A.; García, F.; Díaz-González, L.M.; De Las Heras, C.; Castillo, E.; Fatás, P. Integration of Remote-Sensing Techniques for the Preventive Conservation of Paleolithic Cave Art in the Karst of the Altamira Cave. *Remote Sens.* **2023**, *15*, 1087. [[CrossRef](#)]
27. Xu, Y.; Tong, X.; Stilla, U. Voxel-Based Representation of 3D Point Clouds: Methods, Applications, and Its Potential Use in the Construction Industry. *Autom. Constr.* **2021**, *126*, 103675. [[CrossRef](#)]
28. Poux, F.; Billen, R. Voxel-Based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods. *ISPRS Int. J. Geo-Inf.* **2019**, *8*, 213. [[CrossRef](#)]
29. Raimundo, J.; Lopez-Cuervo Medina, S.; Aguirre De Mata, J.; Prieto, J.F. Multisensor Data Fusion by Means of Voxelization: Application to a Construction Element of Historic Heritage. *Remote Sens.* **2022**, *14*, 4172. [[CrossRef](#)]
30. Alikhodja, N.; Zeglache, H.; Bousnina, M. Remote Sensing Method (TLS) in Architectural Analysis and Constructive Pathology Diagnosis. *Res. Sq.* **2023**. [[CrossRef](#)]
31. Herrero-Tejedor, T.R.; Maté-González, M.Á.; Pérez-Martín, E.; López-Cuervo, S.; López De Herrera, J.; Sánchez-Aparicio, L.J.; Villanueva Llauro, P. Documentation and Virtualisation of Vernacular Cultural Heritage: The Case of Underground Wine Cellars in Atauta (Soria). *Heritage* **2023**, *6*, 5130–5150. [[CrossRef](#)]
32. Suchocki, C.; Błaszczak-Bąk, W.; Janicka, J.; Dumalski, A. Detection of Defects in Building Walls Using Modified OptD Method for Down-Sampling of Point Clouds. *Build. Res. Inf.* **2021**, *49*, 197–215. [[CrossRef](#)]
33. Li, J.; Liu, P.R.; Liang, Z.X.; Wang, X.Y.; Wang, G.Y. Three-Dimensional Geological Modeling Method of Regular Voxel Splitting Based on Multi-Source Data Fusion. *Yantu Lixue Rock Soil Mech.* **2021**, *42*, 1170–1177. [[CrossRef](#)]
34. Goodbody, T.R.; Tompalski, P.; Coops, N.C.; Hopkinson, C.; Treitz, P.; van Ewijk, K. Forest Inventory and Diversity Attribute Modelling Using Structural and Intensity Metrics from Multi-Spectral Airborne Laser Scanning Data. *Remote Sens.* **2020**, *12*, 2109. [[CrossRef](#)]
35. Inano, R.; Oishi, N.; Kunieda, T.; Arakawa, Y.; Yamao, Y.; Shibata, S.; Kikuchi, T.; Fukuyama, H.; Miyamoto, S. Voxel-Based Clustered Imaging by Multiparameter Diffusion Tensor Images for Glioma Grading. *Neuroimage Clin.* **2014**, *5*, 396–407. [[CrossRef](#)] [[PubMed](#)]
36. Li, Y.; Xie, H.; Shin, H. 3D Object Detection Using Frustums and Attention Modules for Images and Point Clouds. *Signals* **2021**, *2*, 98–107. [[CrossRef](#)]
37. Wang, X.; Xu, D.; Gu, F. 3D Model Inpainting Based on 3D Deep Convolutional Generative Adversarial Network. *IEEE Access* **2020**, *8*, 170355–170363. [[CrossRef](#)]
38. Poux, F.; Neuville, R.; Nys, G.A.; Billen, R. 3D Point Cloud Semantic Modelling: Integrated Framework for Indoor Spaces and Furniture. *Remote Sens.* **2018**, *10*, 1412. [[CrossRef](#)]
39. Kuang, H.; Wang, B.; An, J.; Zhang, M.; Zhang, Z. Voxel-FPN: Multi-Scale Voxel Feature Aggregation for 3D Object Detection from LIDAR Point Clouds. *Sensors* **2020**, *20*, 704. [[CrossRef](#)]
40. Gebhardt, S.; Payzer, E.; Salemann, L.; Fettingner, A.; Rotenberg, E.; Seher, C. Polygons, Point-Clouds, and Voxels, A Comparison of High-Fidelity Terrain Representations. In Proceedings of the Fall Simulation Interoperability Workshop 2009, 2009 Fall SIW, Orlando, FL, USA, 21–25 September 2009; pp. 357–365.
41. Arayici, Y.; Counsell, J.; Mahdjoubi, L.; Nagy, G.; Hawas, S.; Dweidar, K. *Heritage Building Information Modelling*; Taylor & Francis Ltd.: London, UK, 2021.
42. Castellazzi, G.; D’Altri, A.; Bitelli, G.; Selvaggi, I.; Lambertini, A. From Laser Scanning to Finite Element Analysis of Complex Buildings by Using a Semi-Automatic Procedure. *Sensors* **2015**, *15*, 18360–18380. [[CrossRef](#)]
43. Bitelli, G.; Castellazzi, G.; D’Altri, A.; De Miranda, S.; Lambertini, A.; Selvaggi, I. Automated Voxel Model from Point Clouds for Structural Analysis of Cultural Heritage. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS* **2016**, *XLI-B5*, 191–197. [[CrossRef](#)]
44. Zhang, C.; Jamshidi, M.; Chang, C.C.; Liang, X.; Chen, Z.; Gui, W. Concrete Crack Quantification Using Voxel-Based Reconstruction and Bayesian Data Fusion. *IEEE Trans. Ind. Inform.* **2022**, *18*, 7512–7524. [[CrossRef](#)]
45. Wang, Y.; Xiao, Y.; Xiong, F.; Jiang, W.; Cao, Z.; Zhou, J.T.; Yuan, J. 3DV: 3D Dynamic Voxel for Action Recognition in Depth Video. In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 13–19 June 2020; pp. 508–517. [[CrossRef](#)]
46. Brock, A.; Lim, T.; Ritchie, J.M.; Weston, N. Generative and Discriminative Voxel Modeling with Convolutional Neural Networks. *arXiv* **2016**, arXiv:1608.04236. [[CrossRef](#)].
47. Li, B. 3D Fully Convolutional Network for Vehicle Detection in Point Cloud. In Proceedings of the 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Vancouver, BC, Canada, 24–28 September 2017; pp. 1513–1518. [[CrossRef](#)]
48. Liu, J.; Mills, S.; McCane, B. Variational Autoencoder for 3D Voxel Compression. In Proceedings of the 2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ), Wellington, New Zealand, 25–27 November 2020; pp. 1–6. [[CrossRef](#)]
49. Huang, B.C.; Feng, Y.C.; Liang, T.Y. A Voxel Generator Based on Autoencoder. *Appl. Sci.* **2022**, *12*, 10757. [[CrossRef](#)]
50. Rezaei, M.; Yang, H.; Meinel, C. Voxel-GAN: Adversarial Framework for Learning Imbalanced Brain Tumor Segmentation. In *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*; Crimi, A., Bakas, S., Kuijf, H., Keyvan, F., Reyes, M., Van Walsum, T., Eds.; Springer International Publishing: Cham, Switzerland, 2019; Volume 11384, pp. 321–333. [[CrossRef](#)]

51. Kleineberg, M.; Fey, M.; Weichert, F. Adversarial Generation of Continuous Implicit Shape Representations. *arXiv* **2020**, arXiv:2002.00349. [[CrossRef](#)].
52. Zhang, W.; Ma, Y.; Zhu, D.; Dong, L.; Liu, Y. MetroGAN: Simulating Urban Morphology with Generative Adversarial Network. In Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Washington, DC, USA, 14–18 August 2022; pp. 2482–2492. [[CrossRef](#)]
53. Kniaz, V.V.; Remondino, F.; Knyaz, V.A. Generative adversarial networks for single photo 3D reconstruction. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS* **2019**, *XLII-2/W9*, 403–408. [[CrossRef](#)]
54. Bastonero, P.; Donadio, E.; Chiabrando, F.; Spanò, A. Fusion of 3D Models Derived from TLS and Image-Based Techniques for CH Enhanced Documentation. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS* **2014**, *2*, 73–80. [[CrossRef](#)]
55. Berra, E.; Gibson-Poole, S.; MacArthur, A.; Gaulton, R.; Hamilton, A. Estimation of the Spectral Sensitivity Functions of Un-Modified and Modified Commercial off-the-Shelf Digital Cameras to Enable Their Use as a Multispectral Imaging System for UAVs. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS Arch.* **2015**, *40*, 207–214. [[CrossRef](#)]
56. Yeshwanth Kumar, A.; Noufia, M.A.; Shahira, K.A.; Ramiya, A.M. Building information modelling of a multi storey building using terrestrial laser scanner and visualisation using potree: An open source point cloud renderer. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. ISPRS* **2019**, *XLII-2/W17*, 421–426. [[CrossRef](#)]
57. Acorsi, M.G.; Gimenez, L.M.; Martello, M. Assessing the Performance of a Low-Cost Thermal Camera in Proximal and Aerial Conditions. *Remote Sens.* **2020**, *12*, 3591. [[CrossRef](#)]
58. Zoreda, L.C.; Mier, M.F.; Pérez, A.R.; Aranz, A.M.; López, P.; Rosado, R.M.; Uzquiano, P. Notas Sobre El Complejo Productivo de Melque (Toledo): Prospección del Territorio y Análisis de Carbono 14, Polínicos, Carpológicos y Antracológicos y de Morteros; In *Archivo Español de Arqueología*; Technical Report; Consejo Superior de Investigaciones Científica: Madrid, Spain, 1999.
59. Ortega, R.; Vanacker, V.; Sanjurjo-Sánchez, J.; Miralles, I. Human-Landscape Interactions during the Early and High Medieval Period in Central Spain Based on New Estimates of Sediment Yield from the Melque Agricultural Complex. *Geoarchaeology* **2017**, *32*, 177–188. [[CrossRef](#)]
60. Zoreda, L.C. Un Canal de Transmisión de Lo Clásico En La Alta Edad Media Española: Arquitectura y Escultura de Influjo Omeya En La Península Ibérica Entre Medios Del Siglo VIII e Inicios Del X (I). *Al-Qantara Rev. Estud. Árabes* **1994**, 321–350.
61. Boehm, J.; Werl, B.; Schuh, H. Troposphere Mapping Functions for GPS and Very Long Baseline Interferometry from European Centre for Medium-Range Weather Forecasts Operational Analysis Data. *J. Geophys. Res. Solid Earth* **2006**, *111*, 2005JB003629. [[CrossRef](#)]
62. Velasco-Gómez, J.; Prieto, J.F.; Molina, I.; Herrero, T.; Fábrega, J.; Pérez-Martín, E. Use of the Gyrotheodolite in Underground Networks of Long High-Speed Railway Tunnels. *Surv. Rev.* **2016**, *48*, 329–337. [[CrossRef](#)]
63. Foley, J.D. *Computer Graphics: Principles and Practice*; Addison Wesley: Boston, MA, USA, 1990.
64. Zhou, Q.Y.; Park, J.; Koltun, V. Open3D: A Modern Library for 3D Data Processing. *arXiv* **2018**, arXiv:1801.09847. [[CrossRef](#)].
65. García-Tejedor, Á.J.; Nogales, A. An Open-Source Python Library for Self-Organizing-Maps. *Softw. Impacts* **2022**, *12*, 100280. [[CrossRef](#)]
66. Ruiz-Varona, A.; Lacasta, J.; Noguera-Iso, J. Self-Organizing Maps to Evaluate Multidimensional Trajectories of Shrinkage in Spain. *ISPRS Int. J. Geo-Inf.* **2022**, *11*, 77. [[CrossRef](#)]
67. Forest, F.; Lebbah, M.; Azzag, H.; Lacaille, J. A Survey and Implementation of Performance Metrics for Self-Organized Maps. *arXiv* **2020**, arXiv:2011.05847. [[CrossRef](#)].
68. Bauer, H.U.; Pawelzik, K.; Geisel, T. A Topographic Product for the Optimization of Self-Organizing Feature Maps. In *Advances in Neural Information Processing Systems*; Moody, J., Hanson, S., Lippmann, R., Eds.; Morgan-Kaufmann: Burlington, MA, USA, 1991; Volume 4.
69. Ortiz, R.; Ortiz, P.; Martín, J.M.; Vázquez, M.A. A New Approach to the Assessment of Flooding and Dampness Hazards in Cultural Heritage, Applied to the Historic Centre of Seville (Spain). *Sci. Total. Environ.* **2016**, *551–552*, 546–555. [[CrossRef](#)]

**Disclaimer/Publisher’s Note:** The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.



## Capítulo 6

# Discusión general, conclusiones y futuras líneas de investigación

«...Te equivocas, eso no es lo que te convierte en un *shinobi*. Un ninja de verdad es aquel que aguanta sin importar qué le echen encima... Déjame explicarte algo. Solo hay una cosa que importa si eres un *shinobi*, y no es el número de técnicas que conozcas. ¡Es tener las agallas para no rendirte jamás!»

---

JIRAIYA, SATO NO KYOKI

La presente Tesis Doctoral ha abordado desafíos significativos en la documentación, conservación y estudio de edificaciones del Patrimonio Histórico mediante el uso avanzado de sensores geoespaciales y técnicas de fusión de datos orientados al análisis de patologías constructivas. A lo largo de esta investigación, se han evaluado y propuesto metodologías para superar las limitaciones existentes en la detección remota y otras tecnologías geomáticas aplicadas al estudio del Patrimonio. Por ello, el objetivo 1 se ha cumplido mediante la exposición del estado del arte (capítulo 1.6) identificando los problemas y campos de trabajo con más potencial de mejora.

Inicialmente, la investigación se centró en la aplicación de técnicas de *pansharpening* para mejorar la resolución de imágenes termográficas, destacando su utilidad y abordando sus limitaciones en resolución comparativas. Este trabajo (capítulo 3) permitió proponer soluciones viables para incrementar la precisión en la documentación mediante este tipo de sensores. La obtención de imágenes de mayor resolución, en este caso en el infrarrojo térmico, cumple con el objetivo 2, propuesto al inicio de esta Tesis.

Continuando con la perspectiva de fusión de datos del artículo anterior, se propuso la técnica de voxelización multispectral (capítulo 4) como método innovador para la fusión de datos multisensor representados en nubes de puntos, abordando los retos asociados con la gestión de grandes volúmenes de datos geomáticos y proponiendo técnicas avanzadas para su análisis.

La finalidad establecida en el objetivo 3 ha sido realizada con éxito.

Y, basándonos en los resultados obtenidos, la investigación culminó con el estudio de la aplicabilidad de los vóxeles multiespectrales en la identificación y localización de anomalías en edificaciones históricas mediante el uso de algoritmos de aprendizaje automático, centrando la atención en un edificio singular en España (capítulo 5). Este desarrollo demostró su utilidad para combinar datos de múltiples sensores para un análisis más profundo y detallado, demostrando su eficacia para la detección y localización de patologías (objetivo 4).

Esta Tesis presenta una coherencia temática sólida a través de los artículos descritos, abordando diferentes aspectos de la fusión de datos geomáticos para mejorar el análisis de estructuras históricas. Esta investigación se fundamenta en la premisa de que la integración de múltiples fuentes de datos puede proporcionar una comprensión más profunda y precisa del estado de conservación de los edificios históricos.

El artículo que explora el aumento de resolución de imágenes térmicas mediante técnicas de *pansharpening* fusionándolas con imágenes del espectro visible (capítulo 3) aborda un aspecto fundamental de la fusión de datos: la mejora de la resolución y la calidad de información de un sensor geomático. Esta mejora es crucial para la detección precisa de patologías como humedades o deterioros estructurales en construcciones. Al fusionar la información del infrarrojo térmico de baja resolución con imágenes de alta resolución del espectro visible, se obtiene una representación más detallada y precisa de las condiciones térmicas del edificio, fundamental para un diagnóstico acertado de su estado. Esta técnica no solo mejora la visualización de los datos, sino que también permite una interpretación más precisa de las anomalías, facilitando la identificación temprana de problemas que podrían pasar desapercibidos con métodos tradicionales. También se hace imprescindible para la generación de nubes de puntos con información termográfica a partir de este tipo de sensores.

Conectando con lo anterior, los artículos que introducen y desarrollan el concepto de vóxel multiespectral (capítulos 4 y 5) representan un avance significativo en la integración de datos multisensor. Esta estrategia permite unificar en una única estructura tridimensional información diversa como datos geométricos, multiespectrales y de otros tipos. La fusión de estos datos en vóxeles multiespectrales facilita un análisis más detallado de las estructuras históricas, permitiendo la identificación de patologías que podrían no ser evidentes al analizar cada conjunto de datos por separado. Los vóxeles multiespectrales actúan como contenedores tridimensionales de información georreferenciada, permitiendo la correlación espacial de diferentes tipos de datos y facilitando el descubrimiento de relaciones complejas entre distintas partes del edificio.

Ambas líneas de investigación convergen en el objetivo común de mejorar la capacidad de detección y análisis de patologías en edificios históricos. Mientras que la superresolución de imágenes térmicas proporciona una mejor visualización y comprensión de las condiciones térmicas, los vóxeles multiespectrales ofrecen una plataforma integrada para el análisis conjunto de múltiples tipos de datos. Esta sinergia entre técnicas permite un estudio más completo de las construcciones, donde la información mejorada de las imágenes térmicas puede integrarse, siempre que esta expresada en nubes de puntos, en la estructura de vóxeles multiespectrales.

La combinación de estas técnicas permite un estudio más profundo y preciso de las edificaciones,

abarcando desde la mejora de datos individuales (como las imágenes térmicas) hasta la integración completa de múltiples fuentes de información. Esta estrategia multisensor facilita la detección de patologías sutiles o en etapas tempranas, como cambios en la composición material o alteraciones en los distintos elementos constructivos de los edificios, que podrían pasar desapercibidas con métodos de inspección convencionales.

Además, la metodología desarrollada en esta Tesis Doctoral no solo se limita al diagnóstico de patologías, sino que también proporciona una base sólida para la planificación de intervenciones de conservación y restauración. La riqueza de los datos fusionados permite una comprensión más profunda de la interacción entre diferentes factores que afectan al estado de conservación del edificio, como la humedad, la temperatura, los materiales y tareas de rehabilitación anteriores.

## 6.1 Avances respecto al estado del arte

Tradicionalmente, el estudio de patologías en edificios se ha basado en el análisis de datos provenientes de sensores individuales o en la interpretación manual de múltiples conjuntos de datos. Los métodos existentes a menudo tratan los diferentes tipos de datos (como imágenes térmicas, nubes de puntos o fotografías multispectrales) de forma separada, lo que puede llevar a una comprensión fragmentada del estado del edificio. Esta fragmentación limita la capacidad de los investigadores para detectar patrones complejos o relaciones sutiles entre diferentes elementos de la edificación.

Hasta ahora, el uso de termografía infrarroja en el estudio de edificios ha estado limitado por la baja resolución espacial de las cámaras térmicas. Esta limitación ha dificultado la detección precisa de pequeñas anomalías térmicas y la interpretación detallada de patrones térmicos complejos en construcciones arquitectónicas. Los métodos existentes a menudo se basan en el análisis directo de estas imágenes de baja resolución o en técnicas de interpolación simples para mejorar su calidad visual.

Mientras que las técnicas actuales de mejora de imágenes térmicas se centran principalmente en el procesamiento de un solo tipo de datos, la metodología propuesta de superresolución por *pansharpening* aprovecha la complementariedad entre diferentes tipos de sensores geomáticos. Esto permite obtener imágenes térmicas de alta resolución que conservan la información térmica original mientras incorporan detalles espaciales finos de otras fuentes de datos.

Además, estas técnicas de aumento de resolución tienen implicaciones significativas para la documentación y monitorización a largo plazo de edificios históricos. La capacidad de generar imágenes térmicas de alta calidad a partir de sensores térmicos de menor costo y más ligeros amplía las posibilidades de realizar estudios térmicos frecuentes y exhaustivos, lo cual es esencial para la conservación preventiva. Las imágenes térmicas de alta resolución obtenidas también pueden incorporarse más fácilmente en modelos 3D o sistemas de información.

Por su lado, la voxelización multispectral propuesta en esta Tesis ofrece una solución innovadora para la integración de datos heterogéneos en una estructura unificada y coherente. Esta estrategia supera las limitaciones de los métodos actuales al permitir la fusión de información geométrica multisensor en una única representación tridimensional. La unificación

de estos datos en vóxeles multiespectrales no solo simplifica el manejo de la información, sino que también facilita el descubrimiento de correlaciones entre diferentes propiedades del edificio que podrían pasar desapercibidas en análisis separados.

Mientras que las técnicas actuales de fusión de datos se centran principalmente en la combinación de información 2D o en la superposición de diferentes capas de datos, la voxelización multiespectral permite una verdadera integración 3D de la información. Esto facilita un análisis más completo y preciso de las estructuras complejas típicas de los edificios históricos. La representación volumétrica georreferenciada permite una mejor comprensión de la distribución espacial de las patologías, así como su relación con el conjunto del edificio, algo que es particularmente valioso en el estudio de construcciones históricas con geometrías complejas o alteraciones a lo largo del tiempo.

Además, la mayoría de los métodos existentes para el estudio de patologías en edificios históricos requieren una interpretación experta de los datos, lo que puede ser subjetivo y consumir mucho tiempo. La metodología propuesta en esta Tesis Doctoral, al combinar la voxelización multiespectral con técnicas de aprendizaje automático como los mapas auto organizados (SOM), permite un análisis más objetivo y automatizado. Esta automatización no solo acelera el proceso de análisis, sino que también reduce la variabilidad introducida por la interpretación humana, permitiendo estudios más consistentes y reproducibles.

Otra ventaja significativa sobre el estado del arte actual es la capacidad de esta metodología para manejar y analizar eficientemente grandes volúmenes de datos. Mientras que los métodos tradicionales a menudo se ven limitados por la cantidad de información que pueden procesar simultáneamente, la estructura de vóxeles multiespectrales permite una gestión más eficiente de los datos, facilitando análisis más exhaustivos y detallados. Esta capacidad es particularmente relevante en la era del *big data*, donde la cantidad de información recopilada sobre edificios históricos está en constante aumento.

En el ámbito de la conservación preventiva, nuestra metodología ofrece nuevas posibilidades que van más allá de las técnicas actuales. La capacidad de integrar y analizar datos históricos junto con nuevas adquisiciones en una estructura coherente permite un seguimiento más preciso de la evolución de las patologías a lo largo del tiempo. Esto facilita la detección temprana de problemas y la planificación de intervenciones más efectivas y menos invasivas.

La voxelización multiespectral también presenta ventajas en términos de escalabilidad y adaptabilidad. Mientras que muchos métodos actuales están optimizados para tipos específicos de datos o estructuras, esta aproximación puede adaptarse fácilmente a diferentes tipos de edificios históricos y a una amplia gama de sensores. Esta flexibilidad es crucial en el campo de la conservación del patrimonio, donde cada edificio presenta desafíos únicos.

Además, la metodología propuesta tiene el potencial de mejorar la colaboración interdisciplinaria en el campo de la conservación del patrimonio. Al proporcionar una representación unificada y comprehensiva de los datos, facilita la comunicación entre diferentes especialistas (arqueólogos, arquitectos, conservadores e ingenieros) que pueden interpretar y trabajar con la misma base de datos integrada.

En resumen, la voxelización multiespectral para la fusión de datos geomáticos multisensor

representa un salto cualitativo en el estudio de patologías en edificios del patrimonio histórico. Su capacidad para integrar datos diversos, facilitar análisis automatizados, manejar grandes volúmenes de información, y proporcionar una visión integral y de conjunto la posiciona como una herramienta innovadora y potencialmente transformadora en este campo.

A continuación exploraremos las conclusiones generales y las futuras líneas de investigación que se proponen a partir de estos estudios, con el objetivo de continuar ampliando los horizontes en la Geomática para la conservación del patrimonio arquitectónico y cultural.

### 6.1.1 Mejora de la resolución en imágenes térmicas infrarrojas utilizando algoritmos de *pansharpening*

Este estudio meticuloso (capítulo 3) ilustra un análisis profundo y detallado de la capacidad de los algoritmos de *pansharpening* para abordar uno de los desafíos más persistentes en la detección remota mediante imágenes térmicas infrarrojas: la mejora de su resolución intrínsecamente limitada. Mediante una metodología exhaustiva y cuantitativa, se logra una evaluación rigurosa que no solo subraya la viabilidad de estos algoritmos para superar las restricciones de resolución, sino que también establece un marco comparativo para medir su eficacia.

A través de la aplicación sistemática de métricas de calidad, se reveló una variabilidad significativa en la efectividad de los distintos algoritmos de *pansharpening*. Mientras algunos algoritmos lograron mejoras notables en la resolución y calidad visual de las imágenes térmicas infrarrojas, otros mostraron un rendimiento menos satisfactorio, destacando la importancia de una selección cuidadosa del algoritmo en función del contexto específico y los objetivos de la aplicación.

La investigación destacó que los algoritmos pertenecientes a la categoría de Análisis Multirresolución (**MRA**) tienden a superar a aquellos de la categoría de Sustitución de Componentes (**CS**) en varios aspectos clave, particularmente en la mejora de la resolución sin comprometer la integridad espectral de las imágenes. Este hallazgo sugiere que los algoritmos **MRA** son más adecuados para aplicaciones donde la fidelidad espectral es crítica. Sin embargo, dentro de la familia **CS**, el algoritmo *Band-Dependent Spatial-Detail* (**BDS**) emergió como una excepción notable, demostrando un rendimiento impresionante en ciertos contextos, especialmente en los datos recopilados por **UAV** en la zona test de Illescas.

Los resultados del estudio también iluminan cómo el rendimiento de los algoritmos de *pansharpening* puede variar notablemente entre diferentes conjuntos de datos. Esta variabilidad enfatiza la relevancia del entorno de aplicación y las características específicas del conjunto de datos en la determinación del algoritmo óptimo. Los algoritmos **MRA** mostraron una robustez notable en ambos conjuntos de datos examinados, mientras que el algoritmo **BDS** destacó en el conjunto de datos de Illescas, lo que sugiere que ciertas características del conjunto de datos pueden influir significativamente en la efectividad del *pansharpening*.

La investigación profundiza en el comportamiento de los algoritmos de *pansharpening* frente a distintos índices de calidad, revelando cómo índices de calidad específicos como **RMSE**, **ERGAS**, **SAM**, **PSNR** y **UQI** pueden ofrecer información sobre la calidad de las imágenes

fusionadas. Los algoritmos [MRA](#) consistentemente exhibieron un desempeño superior en estas métricas, señalando su capacidad para preservar la calidad de la imagen original mientras mejoran su resolución espacial.

Entre los algoritmos examinados, ciertos algoritmos como [BDS](#) y variantes específicas de [MTF-GLP](#) se destacaron por su rendimiento consistente a través de varias medidas. Estos algoritmos demostraron ser particularmente eficaces para la mejora de imágenes térmicas infrarrojas, sugiriendo su potencial para aplicaciones que requieren imágenes de alta calidad y resolución.

Los hallazgos de este estudio tienen implicaciones prácticas significativas para la documentación y análisis del patrimonio histórico, donde usamos distintos sensores con distintas resoluciones, así como para una amplia gama de otras aplicaciones que se benefician de imágenes térmicas de alta resolución. La selección adecuada de algoritmos de *pansharpening*, basada en una evaluación cuantitativa rigurosa, puede mejorar significativamente la resolución de imágenes térmicas infrarrojas, facilitando una mejor comprensión y conservación del patrimonio histórico.

### 6.1.2 Fusión de datos multisensor mediante voxelización

La hipótesis de trabajo presentada (capítulo 4) aborda con éxito los retos inherentes al análisis y la documentación del Patrimonio Histórico mediante la integración de datos multisensor en vóxeles multiespectrales de datos en nubes de puntos. Esta dirección de estudio no solo simplifica el manejo de grandes conjuntos de datos característicos de las nubes de puntos, sino que también proporciona una representación uniforme y detallada del objeto de estudio, facilitando un análisis exhaustivo y preciso de elementos arquitectónicos y arqueológicos. A continuación, profundizamos en los hallazgos y su relevancia:

- Reducción y gestión de datos.

El proceso de voxelización demostró ser excepcionalmente eficaz, reduciendo el número total de puntos a analizar de más de 39 millones a aproximadamente 4,6 millones al aplicar un tamaño de vóxel de 0,5 cm. Este cambio no solo refleja una disminución significativa en el volumen de datos, sino que también mejora la eficiencia en el almacenamiento y procesamiento, marcando un avance sustancial en la gestión de datos de patrimonio histórico. Al reducir la complejidad de los datos, este método permite a los investigadores concentrarse en la información más relevante, optimizando así los recursos computacionales y humanos involucrados en el análisis.

- Uniformidad y detalle en la representación.

La estrategia de voxelización asegura una resolución geométrica uniforme a lo largo del objeto investigado. Esta homogeneización es fundamental para eliminar redundancias y mejorar significativamente la representación de áreas con densidades variables de puntos, lo que resulta en una visualización más precisa y detallada de los elementos estudiados.

- Flexibilidad en la resolución.

La capacidad de ajustar el tamaño de los vóxeles según las necesidades específicas del proyecto destaca la versatilidad del método. La variabilidad en el número de vóxeles

generados, dependiendo del tamaño seleccionado, subraya la capacidad del método para adaptarse a diversos niveles de detalle requeridos en estudios del patrimonio.

- Fusión efectiva de datos multispectrales.

La implementación de vóxeles multispectrales permite una integración eficiente de datos geométricos y espectrales de diversas fuentes, enriqueciendo el análisis con una comprensión más profunda de las características físicas y químicas de los elementos arquitectónicos. Esta riqueza de información es invaluable para identificar patologías, diferencias en materiales y otros aspectos críticos para la conservación y restauración del patrimonio.

- Avances en análisis y aplicaciones futuras.

La estructura de datos resultante se presenta como una plataforma ideal para la aplicación de técnicas avanzadas de aprendizaje automático, potenciando la automatización en la clasificación y análisis detallado de datos tridimensionales. La posibilidad de fusionar datos con información de diversas bandas espectrales podría revolucionar la forma en que se documentan y analizan los sitios de patrimonio histórico, mejorando la resolución y la calidad de la información disponible para la investigación.

En resumen, los resultados de esta investigación marcan un hito en la fusión de datos multisensor para el estudio del patrimonio histórico, demostrando cómo la voxelización multispectral no solo aborda los desafíos de manejo de grandes volúmenes de datos, sino que también abre el camino hacia análisis más detallados y precisos. Esta propuesta metodológica sienta las bases para la siguiente investigación destinada a ir más allá de la fusión de nubes de puntos, ampliando así el alcance y la precisión en el estudio y conservación del Patrimonio Histórico.

### **6.1.3 Fusión avanzada de datos multisensor con aprendizaje profundo mediante vóxeles multispectrales**

Esta investigación (capítulo 5) profundiza en la fusión de datos multisensor a través de vóxeles multispectrales para estudiar de manera detallada la estructura y patologías presentes en la Iglesia Visigoda de Santa María de Melque, aplicando mapas auto organizados (SOM) para clasificar y analizar estos complejos conjuntos de datos. Esta línea de trabajo ha demostrado ser particularmente eficaz en abordar retos como la heterogeneidad de los datos y su volumen masivo, características comunes en la documentación del patrimonio histórico.

A través de una metodología rigurosa, se ha logrado una optimización notable en la representación de datos, evidenciada por la reducción significativa del número de elementos a analizar y la mejora en la gestión de datos. Este proceso no solo simplifica el análisis posterior, sino que también asegura una resolución geométrica uniforme a lo largo del objeto de estudio, lo cual es fundamental para una representación precisa y detallada de las estructuras y sus afecciones. Además, se ha demostrado la flexibilidad del método para adaptarse a diferentes necesidades de resolución, pudiendo ajustar el tamaño de los vóxeles según los requerimientos específicos del análisis.

Uno de los hallazgos más significativos del estudio es la identificación y localización eficaz de patologías, como la humedad y las eflorescencias, en las estructuras del edificio. Mediante el análisis de los patrones y características específicas de los vóxeles clasificados por los SOM, se han destacado áreas afectadas dentro de la estructura, proporcionando una base sólida para acciones de conservación dirigidas y eficientes. Esta línea de trabajo facilita una comprensión más profunda de las condiciones estructurales del edificio y sus potenciales problemas, permitiendo intervenciones más informadas y efectivas en la preservación del patrimonio.

Y entre los hallazgos generales de este artículo, podemos destacar:

- Mejora en la detección de patologías.

La investigación conlleva mejoras significativas en la detección temprana y el diagnóstico de patologías arquitectónicas, facilitando intervenciones más oportunas y menos invasivas.

- Contribución al campo de la conservación del patrimonio.

Al proporcionar un conocimiento más profundo de las relaciones entre las bandas espectrales y las patologías de los edificios, esta línea de investigación enriquece el campo de la conservación del patrimonio con herramientas y metodologías innovadoras.

- Aplicaciones en restauración y mantenimiento.

Los resultados podrían informar las prácticas de restauración y mantenimiento, ofreciendo a los conservadores y restauradores una base científica para tomar decisiones informadas sobre las técnicas de intervención más adecuadas.

## 6.2 Futuras líneas de investigación

En base a los resultados y avances obtenidos en esta Tesis Doctoral, proponemos dos líneas que pensamos son prometedoras para futuras investigaciones en la aplicación de tecnologías geomáticas en la conservación del patrimonio:

1. Desarrollo de algoritmos de *pansharpening* especializados para imágenes térmicas.

La necesidad de mejorar la calidad y la utilidad de las imágenes térmicas en contextos críticos como la conservación del patrimonio ha impulsado la propuesta de desarrollar algoritmos de *pansharpening* que se especialicen en la fusión de estas imágenes con datos de otras bandas espectrales:

- Optimización para imágenes térmicas: diseñar algoritmos de *pansharpening* que tengan en cuenta las propiedades únicas de las imágenes termográficas, asegurando que la fusión preserve la integridad de la información térmica.
- Integración multispectral efectiva: permitir una fusión precisa de imágenes térmicas con datos de alta resolución de otras bandas espectrales, mejorando así su resolución espacial y calidad sin comprometer la integridad espectral de ninguna banda.

- Aplicabilidad universal: asegurar que estos algoritmos sean adaptables a una variedad de plataformas de registro, incluidos satélites, UAVs y sistemas terrestres, ampliando su utilidad a otros campos como la agricultura de precisión y la gestión ambiental. Este análisis requeriría un trabajo colaborativo entre especialistas en Geomática e investigadores en otros campos de conocimiento, con el objetivo de probar y validar los nuevos algoritmos en distintos escenarios y con diversos tipos de datos.
2. Diagnóstico de patologías en edificios arquitectónicos mediante análisis espectral multi-sensor.

Basado en la comprensión de que diferentes patologías presentan firmas espectrales únicas, esta línea de investigación buscaría avanzar en la precisión y efectividad, apoyándose en los vóxeles multispectrales y su entrenamiento con los mapas auto organizados (SOM), en la detección y diagnóstico de condiciones patológicas en edificios arquitectónicos:

- Catalogación de patologías específicas respecto a los distintos sensores empleados: identificar y documentar las patologías más comunes en edificaciones patrimoniales, con especial interés en aquellas que impactan significativamente en la conservación y rehabilitación de los edificios.
- Correlación entre bandas espectrales y patologías: establecer relaciones claras entre diversas bandas espectrales y patologías específicas, determinando qué combinaciones son más efectivas para su detección.
- Desarrollo de guías de diagnóstico para tomas de datos multisensor: formular guías detalladas para el uso de la detección remota en el diagnóstico de patologías arquitectónicas, utilizando distintos sensores describiendo las particularidades y posibilidades de cada uno.

Este trabajo implicaría una extensa recopilación y análisis de datos multisensor de edificaciones con diversas patologías, utilizando tecnologías avanzadas de adquisición de datos y algoritmos de procesamiento aplicando los vóxeles multispectrales.

- Integración de técnicas de visualización con realidad virtual y aumentada: la adopción de metodologías de visualización basadas en realidad virtual y aumentada, apoyadas en la potencia de procesamiento de los vóxeles multispectrales, representa un campo de investigación emergente que puede transformar la manera en que los investigadores estudian y interactúan con edificios históricos.

Utilizar la realidad virtual y aumentada para proporcionar representaciones tridimensionales e inmersivas de los datos geomáticos, mejorando la interpretación y el análisis de patologías en edificaciones históricas, permitirá a los investigadores manipular y explorar digitalmente reconstrucciones detalladas de edificios patrimoniales, mejorando la precisión y eficiencia en la identificación de problemas estructurales.

Estas propuestas de investigación no solo buscan superar las limitaciones técnicas actuales, sino también expandir la aplicabilidad de las técnicas geomáticas a una gama más amplia

de problemas en la conservación del patrimonio. Al combinar innovación técnica con una comprensión profunda de las necesidades del patrimonio arquitectónico, estas investigaciones tienen el potencial de ofrecer soluciones más precisas, efectivas y adaptadas a las necesidades específicas de estudio en la conservación de edificaciones históricas.

Con todas estas contribuciones, esta Tesis Doctoral aspira a ser un hito dentro del estudio interdisciplinario de la conservación del patrimonio, ofreciendo perspectivas innovadoras y soluciones prácticas para los desafíos que enfrenta la preservación de nuestro legado cultural arquitectónico.

# Referencias

- [1] Efstathios Adamopoulos y Fulvio Rinaudo. “Close-Range Sensing and Data Fusion for Built Heritage Inspection and Monitoring—A Review”. En: *Remote Sensing* 13.19 (oct. de 2021), pág. 3936. DOI: [10.3390/rs13193936](https://doi.org/10.3390/rs13193936) (vid. págs. 21, 27, 87, 116).
- [2] Mario Ivan Alba et al. “Mapping Infrared Data on Terrestrial Laser Scanning 3D Models of Buildings”. En: *Remote Sensing* 3.9 (ago. de 2011), págs. 1847-1870. DOI: [10.3390/rs3091847](https://doi.org/10.3390/rs3091847) (vid. págs. 2, 17, 18).
- [3] A. T. Albourae, C. Armenakis y M. Kyan. “Architectural Heritage Visualization Using Interactive Technologies”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Vol. 42. 2017, págs. 7-13. DOI: [10.5194/isprs-archives-XLII-2-W5-7-2017](https://doi.org/10.5194/isprs-archives-XLII-2-W5-7-2017) (vid. pág. 8).
- [4] Thiemo Alldieck, Chris Bahnsen y Thomas Moeslund. “Context-Aware Fusion of RGB and Thermal Imagery for Traffic Monitoring”. En: *Sensors* 16.11 (nov. de 2016), pág. 1947. DOI: [10.3390/s16111947](https://doi.org/10.3390/s16111947) (vid. pág. 28).
- [5] Feras Almasri y Olivier Debeir. “Multimodal Sensor Fusion in Single Thermal Image Super-Resolution”. En: *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Vol. 11367 LNCS. Dic. de 2019, págs. 418-433. DOI: [10.1007/978-3-030-21074-8\\_34](https://doi.org/10.1007/978-3-030-21074-8_34). arXiv: [1812.09276](https://arxiv.org/abs/1812.09276) (vid. pág. 48).
- [6] Kinjiro Amano, Eric C.W. Lou y Rodger Edwards. “Integration of Point Cloud Data and Hyperspectral Imaging as a Data Gathering Methodology for Refurbishment Projects Using Building Information Modelling (BIM)”. En: *Journal of Facilities Management* 17.1 (feb. de 2019), págs. 57-75. DOI: [10.1108/JFM-11-2017-0064](https://doi.org/10.1108/JFM-11-2017-0064) (vid. pág. 19).
- [7] Mesrop Andriasyan et al. “From Point Cloud Data to Building Information Modelling: An Automatic Parametric Workflow for Heritage”. En: *Remote Sensing* 12.7 (abr. de 2020). DOI: [10.3390/rs12071094](https://doi.org/10.3390/rs12071094) (vid. págs. 21, 22).
- [8] P. Bastonero et al. “Fusion of 3D Models Derived from TLS and Image-Based Techniques for CH Enhanced Documentation”. En: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* II-5 (mayo de 2014), págs. 73-80. DOI: [10.5194/isprsannals-II-5-73-2014](https://doi.org/10.5194/isprsannals-II-5-73-2014) (vid. pág. 25).
- [9] Hans-Ulrich Bauer, Klaus Pawelzik y Theo Geisel. “A Topographic Product for the Optimization of Self-Organizing Feature Maps”. En: *Advances in Neural Information Processing Systems*. Ed. por J. Moody, S. Hanson y R.P. Lippmann. Vol. 4. Morgan-Kaufmann, 1991 (vid. págs. 128, 129).

- [10] Vicente Bayarri et al. “Integration of Remote-Sensing Techniques for the Preventive Conservation of Paleolithic Cave Art in the Karst of the Altamira Cave”. En: *Remote Sensing* 15.4 (feb. de 2023), pág. 1087. DOI: [10.3390/rs15041087](https://doi.org/10.3390/rs15041087) (vid. pág. 6).
- [11] E. Berra et al. “Estimation of the Spectral Sensitivity Functions of Un-Modified and Modified Commercial off-the-Shelf Digital Cameras to Enable Their Use as a Multispectral Imaging System for UAVs”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 40.1W4 (2015), págs. 207-214. DOI: [10.5194/isprsarchives-XL-1-W4-207-2015](https://doi.org/10.5194/isprsarchives-XL-1-W4-207-2015) (vid. pág. 90).
- [12] G. Bitelli et al. “Automated Voxel Model from Point Clouds for Structural Analysis of Cultural Heritage”. En: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLI-B5.September (jun. de 2016), págs. 191-197. DOI: [10.5194/isprsarchives-XLI-B5-191-2016](https://doi.org/10.5194/isprsarchives-XLI-B5-191-2016) (vid. pág. 23).
- [13] S. Chatzistamatis et al. “Fusion of TLS and UAV Photogrammetry Data for Post-Earthquake 3D Modeling of a Cultural Heritage Church”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Vol. 42. 2018, págs. 143-150. DOI: [10.5194/isprs-archives-XLII-3-W4-143-2018](https://doi.org/10.5194/isprs-archives-XLII-3-W4-143-2018) (vid. pág. 19).
- [14] P. S. Chavez, S. C. Sides y J. A. Anderson. “Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and SPOT Panchromatic”. En: *Photogrammetric Engineering & Remote Sensing* 57.3 (1991), págs. 295-303. DOI: [10.1306/44b4c288-170a-11d7-8645000102c1865d](https://doi.org/10.1306/44b4c288-170a-11d7-8645000102c1865d) (vid. págs. 51, 52).
- [15] Xiaohui Chen et al. “Color Guided Thermal Image Super Resolution”. En: *2016 Visual Communications and Image Processing (VCIP)*. Chengdu, China: IEEE, nov. de 2016, págs. 1-4. DOI: [10.1109/VCIP.2016.7805509](https://doi.org/10.1109/VCIP.2016.7805509) (vid. pág. 31).
- [16] F. Chiabrando et al. “UAV and RPV Systems for Photogrammetric Surveys in Archaeological Areas: Two Tests in the Piedmont Region (Italy)”. En: *Journal of Archaeological Science* 38.3 (mar. de 2011), págs. 697-710. DOI: [10.1016/j.jas.2010.10.022](https://doi.org/10.1016/j.jas.2010.10.022) (vid. pág. 7).
- [17] Jaewan Choi, Kiyun Yu y Yongil Kim. “A New Adaptive Component-Substitution-Based Satellite Image Fusion by Using Partial Replacement”. En: *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 49. 2011, págs. 295-309. DOI: [10.1109/TGRS.2010.2051674](https://doi.org/10.1109/TGRS.2010.2051674) (vid. pág. 52).
- [18] M. Codiglione, G. Mazzacca y F. Remondino. “Dimensional Discoveries: Unveiling the Potential of 3d Heritage Point Clouds with a Robust Ontology Framework”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLVIII-2/W4-2024 (feb. de 2024), págs. 119-125. DOI: [10.5194/isprs-archives-XLVIII-2-W4-2024-119-2024](https://doi.org/10.5194/isprs-archives-XLVIII-2-W4-2024-119-2024) (vid. págs. 21, 116).
- [19] Miguel Angel Conejo-Martín et al. “Characterization of Underground Cellars in the Duero Basin by GNSS, LIDAR and GPR Techniques”. En: *Mathematics of Planet Earth*. Ed. por Eulogio Pardo-Igúzquiza et al. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, págs. 277-280. DOI: [10.1007/978-3-642-32408-6\\_62](https://doi.org/10.1007/978-3-642-32408-6_62) (vid. pág. 6).
- [20] Antonio Costanzo et al. “Combined Use of Terrestrial Laser Scanning and IR Thermography Applied to a Historical Building”. En: *Sensors* 15.1 (dic. de 2014), págs. 194-213. DOI: [10.3390/s150100194](https://doi.org/10.3390/s150100194) (vid. pág. 7).

- [21] Marie Cottrell et al. “Self-Organizing Maps, Theory and Applications”. En: *Revista de Investigacion Operacional* 39 (ene. de 2018), págs. 1-22 (vid. págs. [125](#), [126](#)).
- [22] Kevser Irem Danaci y Erdem Akagunduz. *A Survey on Infrared Image and Video Sets*. Ene. de 2023. arXiv: [2203.08581 \[cs\]](#) (vid. págs. [28](#), [30](#)).
- [23] M. Del Giudice y A. Osello. “Bim for Cultural Heritage”. En: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-5/W2 (2013), págs. 225-229. DOI: [10.5194/isprsarchives-xl-5-w2-225-2013](#) (vid. pág. [7](#)).
- [24] S. Del Pozo et al. “Multi-Sensor Radiometric Study to Detect Pathologies in Historical Buildings”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 40.5W4 (feb. de 2015), págs. 193-200. DOI: [10.5194/isprsarchives-XL-5-W4-193-2015](#) (vid. págs. [36](#), [135](#)).
- [25] S. Del Pozo et al. “Multispectral Imaging in Cultural Heritage Conservation”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Vol. 42. International Society for Photogrammetry and Remote Sensing, ago. de 2017, págs. 155-162. DOI: [10.5194/isprs-archives-XLII-2-W5-155-2017](#) (vid. pág. [135](#)).
- [26] Susana Del Pozo et al. “Multispectral Radiometric Analysis of Façades to Detect Pathologies from Active and Passive Remote Sensing”. En: *Remote Sensing* 8.1 (ene. de 2016), pág. 80. DOI: [10.3390/rs8010080](#) (vid. págs. [37](#), [133](#), [135](#)).
- [27] C. Dore y M. Murphy. “Integration of Historic Building Information Modeling (HBIM) and 3D GIS for Recording and Managing Cultural Heritage Sites”. En: *2012 18th International Conference on Virtual Systems and Multimedia*. Milan, Italy: IEEE, sep. de 2012, págs. 369-376. DOI: [10.1109/VSMM.2012.6365947](#) (vid. pág. [8](#)).
- [28] Birgitta Dresp-Langley, John Mwangi Wandeto y Henry Okola Nyongesa. *Using the Quantization Error from Self-Organizing Map (SOM) Output for Fast Detection of Critical Variations in Image Time Series*. Mar. de 2018. DOI: [10.20944/preprints201710.0166.v2](#) (vid. pág. [127](#)).
- [29] James D Foley. *Computer Graphics: Principles and Practice*. Addison Wesley, 1990 (vid. pág. [90](#)).
- [30] William Frodella et al. “Combining InfraRed Thermography and UAV Digital Photogrammetry for the Protection and Conservation of Rupestrian Cultural Heritage Sites in Georgia: A Methodological Application”. En: *Remote Sensing* 12.5 (mar. de 2020), pág. 892. DOI: [10.3390/rs12050892](#) (vid. págs. [30](#), [31](#)).
- [31] Miguel Ángel García Guinea y Manuel Gómez-Moreno. *El arte románico en Palencia*. 2. ed. Coleccion Pallantia 3. Palencia: Ed. de la Excma. Diputacion Provincial de Palencia, 1975 (vid. pág. [4](#)).
- [32] Álvaro José García-Tejedor y Alberto Nogales. “An Open-Source Python Library for Self-Organizing-Maps”. En: *Software Impacts* 12. February (mayo de 2022), pág. 100280. DOI: [10.1016/j.simpa.2022.100280](#) (vid. págs. [126](#), [130](#)).
- [33] Iván Garrido et al. “Review of InfraRed Thermography and Ground-Penetrating Radar Applications for Building Assessment”. En: *Advances in Civil Engineering* 2022 (sep. de 2022). Ed. por Alessandro Rasulo, págs. 1-20. DOI: [10.1155/2022/5229911](#) (vid. págs. [6](#), [7](#)).

- [34] Andrea Garzelli, Filippo Nencini y Luca Capobianco. “Optimal MMSE Pan Sharpening of Very High Resolution Multispectral Images”. En: *IEEE Transactions on Geoscience and Remote Sensing* 46.1 (2008), págs. 228-236. DOI: [10.1109/TGRS.2007.907604](https://doi.org/10.1109/TGRS.2007.907604) (vid. pág. 52).
- [35] Eleonora Grilli y Fabio Remondino. “Classification of 3D Digital Heritage”. En: *Remote Sensing* 11.7 (abr. de 2019), pág. 847. DOI: [10.3390/rs11070847](https://doi.org/10.3390/rs11070847) (vid. págs. 21, 116).
- [36] Eleonora Grilli y Fabio Remondino. “Machine Learning Generalisation across Different 3D Architectural Heritage”. En: *ISPRS International Journal of Geo-Information* 9.6 (jun. de 2020), pág. 379. DOI: [10.3390/ijgi9060379](https://doi.org/10.3390/ijgi9060379) (vid. pág. 116).
- [37] Alberto Guarnieri, Nicola Milan y Antonio Vettore. “Monitoring Of Complex Structure For Structural Control Using Terrestrial Laser Scanning (Tls) And Photogrammetry”. En: *International Journal of Architectural Heritage* 7.1 (ene. de 2013), págs. 54-67. DOI: [10.1080/15583058.2011.606595](https://doi.org/10.1080/15583058.2011.606595) (vid. pág. 5).
- [38] Ludwig Hoegner, Sebastian Tuttas y Uwe Stilla. “3D Building Reconstruction and Construction Site Monitoring from RGB and TIR Image Sets”. En: *2016 12th International Symposium on Electronics and Telecommunications, ISETC 2016 - Conference Proceedings*. IEEE, oct. de 2016, págs. 305-308. DOI: [10.1109/ISETC.2016.7781118](https://doi.org/10.1109/ISETC.2016.7781118) (vid. pág. 19).
- [39] Seungtaek Jeong et al. “Construction of an Unmanned Aerial Vehicle Remote Sensing System for Crop Monitoring”. En: *Journal of Applied Remote Sensing* 10.2 (jun. de 2016), pág. 026027. DOI: [10.1117/1.JRS.10.026027](https://doi.org/10.1117/1.JRS.10.026027) (vid. pág. 36).
- [40] Isabel Jordan-Palomar et al. “Protocol to Manage Heritage-Building Interventions Using Heritage Building Information Modelling (HBIM)”. En: *Sustainability (Switzerland)* 10.4 (mar. de 2018), pág. 908. DOI: [10.3390/su10040908](https://doi.org/10.3390/su10040908) (vid. pág. 7).
- [41] Hyung Sup Jung y Sung Whan Park. “Multi-Sensor Fusion of Landsat 8 Thermal Infrared (TIR) and Panchromatic (PAN) Images”. En: *Sensors (Switzerland)* 14.12 (dic. de 2014), págs. 24425-24440. DOI: [10.3390/s141224425](https://doi.org/10.3390/s141224425) (vid. pág. 35).
- [42] Muhammad Murtaza Khan et al. “Indusion: Fusion of Multispectral and Panchromatic Images Using the Indusion Scaling Technique”. En: *IEEE Geoscience and Remote Sensing Letters* 5.1 (2008), págs. 98-102. DOI: [10.1109/LGRS.2007.909934](https://doi.org/10.1109/LGRS.2007.909934) (vid. pág. 53).
- [43] C. Kivilcim y Z. Duran. “A Semi- Automated Point Cloud Processing Methodology for 3D Cultural Heritage Documentation”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Vol. 41. 2016, págs. 293-296. DOI: [10.5194/isprsarchives-XLI-B5-293-2016](https://doi.org/10.5194/isprsarchives-XLI-B5-293-2016) (vid. pág. 23).
- [44] Margaret Kohin y Neal R. Butler. “Performance Limits of Uncooled VO x Microbolometer Focal Plane Arrays”. En: *Infrared Technology and Applications XXX*. Ed. por Bjorn F. Andresen y Gabor F. Fulop. Vol. 5406. Ago. de 2004, pág. 447. DOI: [10.1117/12.542482](https://doi.org/10.1117/12.542482) (vid. pág. 48).
- [45] Teuvo Kohonen. “Self-Organized Formation of Topologically Correct Feature Maps”. En: *Biological Cybernetics* 43.1 (1982), págs. 59-69. DOI: [10.1007/BF00337288](https://doi.org/10.1007/BF00337288) (vid. pág. 125).
- [46] Claudia Kuenzer y Stefan Dech. “Thermal Remote Sensing Sensors, Methods, Applications”. En: *Remote Sensing and Digital Image Processing*. Ed. por Claudia Kuenzer

- y Stefan Dech. Vol. 17. Dordrecht: Springer Netherlands, 2013, págs. 287-313. DOI: [10.1007/978-94-007-6639-6](https://doi.org/10.1007/978-94-007-6639-6) (vid. pág. 48).
- [47] Soonwook Kwon et al. “Development of Optimized Point Cloud Merging Algorithms for Accurate Processing to Create Earthwork Site Models”. En: *Automation in Construction* 35 (nov. de 2013), págs. 618-624. DOI: [10.1016/j.autcon.2013.01.004](https://doi.org/10.1016/j.autcon.2013.01.004) (vid. pág. 85).
- [48] C.A Laben y B.V Brower. “Process for Enhancing the Spatial Resolution of Multispectral Imagery Using Pan-Sharpener”. En: *United States Patent 6 11* (2000), pág. 875 (vid. pág. 52).
- [49] S. Lagüela et al. “Calibration and Verification of Thermographic Cameras for Geometric Measurements”. En: *Infrared Physics and Technology* 54.2 (mar. de 2011), págs. 92-99. DOI: [10.1016/j.infrared.2011.01.002](https://doi.org/10.1016/j.infrared.2011.01.002) (vid. pág. 50).
- [50] S. Lagüela et al. “Automation of Thermographic 3D Modelling through Image Fusion and Image Matching Techniques”. En: *Automation in Construction* 27 (nov. de 2012), págs. 24-31. DOI: [10.1016/j.autcon.2012.05.011](https://doi.org/10.1016/j.autcon.2012.05.011) (vid. págs. 17, 28, 48).
- [51] Wenzhi Liao et al. “Two-Stage Fusion of Thermal Hyperspectral and Visible RGB Image by PCA and Guided Filter”. En: *2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. Tokyo, Japan: IEEE, jun. de 2015, págs. 1-4. DOI: [10.1109/WHISPERS.2015.8075405](https://doi.org/10.1109/WHISPERS.2015.8075405) (vid. pág. 35).
- [52] Dong Lin et al. “Fusion of Thermal Imagery with Point Clouds for Building Façade Thermal Attribute Mapping”. En: *ISPRS Journal of Photogrammetry and Remote Sensing* 151 (mayo de 2019), págs. 162-175. DOI: [10.1016/j.isprsjprs.2019.03.010](https://doi.org/10.1016/j.isprsjprs.2019.03.010) (vid. págs. 21, 31, 116).
- [53] J. G. Liu. “Smoothing Filter-based Intensity Modulation: A Spectral Preserve Image Fusion Technique for Improving Spatial Details”. En: *International Journal of Remote Sensing* 21.18 (2000), págs. 3461-3472. DOI: [10.1080/014311600750037499](https://doi.org/10.1080/014311600750037499) (vid. pág. 52).
- [54] David G. Lowe. “Distinctive Image Features from Scale-Invariant Keypoints”. En: *International Journal of Computer Vision* 60.2 (nov. de 2004), págs. 91-110. DOI: [10.1023/B:VISI.0000029664.99615.94](https://doi.org/10.1023/B:VISI.0000029664.99615.94) (vid. pág. 4).
- [55] M. Maghiar et al. “Historic Bim for Preservation Documentation and Management Application”. En: *BIM Academic Symposium*. 2017 (vid. pág. 7).
- [56] M. S. Maguire et al. “Thermal Infrared and Multi-Spectral Dual Sensor Integration for Unmanned Aircraft Systems”. En: *2017 ASABE Annual International Meeting*. 2017. DOI: [10.13031/aim.201701455](https://doi.org/10.13031/aim.201701455) (vid. pág. 26).
- [57] Emanuele Mandanici et al. “A Multi-Image Super-Resolution Algorithm Applied to Thermal Imagery”. En: *Applied Geomatics* 11.3 (sep. de 2019), págs. 215-228. DOI: [10.1007/s12518-019-00253-y](https://doi.org/10.1007/s12518-019-00253-y) (vid. pág. 33).
- [58] E. Maset et al. “Photogrammetric 3D Building Reconstruction from Thermal Images”. En: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 4.2W3 (ago. de 2017), págs. 25-32. DOI: [10.5194/isprs-annals-IV-2-W3-25-2017](https://doi.org/10.5194/isprs-annals-IV-2-W3-25-2017) (vid. pág. 29).
- [59] A. Masiero y D. Costantino. “TLS for Detecting Small Damages on a Building Façade”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-2/W11* (mayo de 2019), págs. 831-836. DOI: [10.5194/isprs-archives-xlii-2-w11-831-2019](https://doi.org/10.5194/isprs-archives-xlii-2-w11-831-2019) (vid. pág. 2).

- [60] Miguel Ángel Maté-González, Vincenzo Di Pietra y Marco Piras. “Evaluation of Different LiDAR Technologies for the Documentation of Forgotten Cultural Heritage under Forest Environments”. En: *Sensors* 22.16 (ago. de 2022), pág. 6314. DOI: [10.3390/s22166314](https://doi.org/10.3390/s22166314) (vid. pág. 6).
- [61] F. Matrone et al. “A Benchmark for Large-Scale Heritage Point Cloud Semantic Segmentation”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLIII-B2-2020 (ago. de 2020), págs. 1419-1426. DOI: [10.5194/isprs-archives-xliii-b2-2020-1419-2020](https://doi.org/10.5194/isprs-archives-xliii-b2-2020-1419-2020) (vid. pág. 21).
- [62] Francesca Matrone et al. “Comparing Machine and Deep Learning Methods for Large 3D Heritage Semantic Segmentation”. En: *ISPRS International Journal of Geo-Information* 9.9 (sep. de 2020), pág. 535. DOI: [10.3390/ijgi9090535](https://doi.org/10.3390/ijgi9090535) (vid. pág. 116).
- [63] G. Mazzacca et al. “Seeing among Foliage with Lidar and Machine Learning: Towards a Transferable Archaeological Pipeline”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLVI-2/W1-2022 (feb. de 2022), págs. 365-372. DOI: [10.5194/isprs-archives-XLVI-2-W1-2022-365-2022](https://doi.org/10.5194/isprs-archives-XLVI-2-W1-2022-365-2022) (vid. pág. 116).
- [64] F. Mercuri et al. “Infrared Thermography Applied to the Study of Cultural Heritage”. En: *International Journal of Thermophysics* 36.5-6 (jun. de 2015), págs. 1189-1194. DOI: [10.1007/s10765-014-1645-x](https://doi.org/10.1007/s10765-014-1645-x) (vid. pág. 18).
- [65] Merino de Caceres, Jose Miguel. *La Iglesia de La Vera-cruz de Segovia, Conocida Como de Los Templarios*. Segovia al Paso 5. Academia de Historia y Arte de San Quirce, 1998 (vid. pág. 5).
- [66] Meydenbauer, Albrecht. “Pioneer of Photogrammetric Documentation of the Cultural Heritage”. En: *Proceedings of the XVIII International Symposium of CIPA, ICOMOS / UNESCO / ISPRS, Postdam*. 2001 (vid. pág. 4).
- [67] Antonia Moropoulou et al. “Non-Destructive Techniques as a Tool for the Protection of Built Cultural Heritage”. En: *Construction and Building Materials* 48 (2013), págs. 1222-1239. DOI: [10.1016/j.conbuildmat.2013.03.044](https://doi.org/10.1016/j.conbuildmat.2013.03.044) (vid. págs. 7, 24).
- [68] Juan Moyano et al. “Semantic Interpretation of Architectural and Archaeological Geometries: Point Cloud Segmentation for HBIM Parameterisation”. En: *Automation in Construction* 130 (oct. de 2021), pág. 103856. DOI: [10.1016/j.autcon.2021.103856](https://doi.org/10.1016/j.autcon.2021.103856) (vid. pág. 116).
- [69] Maurice Murphy, Eugene MCGovern y Sara Pavia. “Historic Building Information Modelling (HBIM)”. En: *Structural Survey* 27.4 (2009), págs. 311-327. DOI: [10.1108/02630800910985108](https://doi.org/10.1108/02630800910985108) (vid. pág. 7).
- [70] A. Murtiyoso y P. Grussenmeyer. “Point Cloud Segmentation and Semantic Annotation Aided by Gis Data for Heritage Complexes”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLII-2/W9 (ene. de 2019), págs. 523-528. DOI: [10.5194/isprs-archives-XLII-2-W9-523-2019](https://doi.org/10.5194/isprs-archives-XLII-2-W9-523-2019) (vid. pág. 116).
- [71] Antonella Musicco et al. “Automatic Point Cloud Segmentation for the Detection of Alterations on Historical Buildings Through an Unsupervised and Clustering-Based Machine Learning Approach”. En: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* V-2-2021 (jun. de 2021), págs. 129-136. DOI: [10.5194/isprs-annals-V-2-2021-129-2021](https://doi.org/10.5194/isprs-annals-V-2-2021-129-2021) (vid. pág. 38).

- [72] M. Naumann et al. “Accuracy Comparison of Digital Surface Models Created by Unmanned Aerial Systems Imagery and Terrestrial Laser Scanner”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-1/W2 (ago. de 2013), págs. 281-286. DOI: [10.5194/isprsarchives-XL-1-W2-281-2013](https://doi.org/10.5194/isprsarchives-XL-1-W2-281-2013) (vid. pág. 6).
- [73] Juan Enrique Nieto et al. “Management of Built Heritage via HBIM Project: A Case of Study of Flooring and Tiling”. En: *Virtual Archaeology Review* 7.14 (mayo de 2016), pág. 1. DOI: [10.4995/var.2016.4349](https://doi.org/10.4995/var.2016.4349) (vid. págs. 7, 20).
- [74] Tarek Omar y Moncef L. Nehdi. “Remote Sensing of Concrete Bridge Decks Using Unmanned Aerial Vehicle Infrared Thermography”. En: *Automation in Construction* 83.June (nov. de 2017), págs. 360-371. DOI: [10.1016/j.autcon.2017.06.024](https://doi.org/10.1016/j.autcon.2017.06.024) (vid. pág. 38).
- [75] Zaid Omar y Tania Stathaki. “Image Fusion: An Overview”. En: *Proceedings - International Conference on Intelligent Systems, Modelling and Simulation, ISMS 2015-Septe* (2015), págs. 306-310. DOI: [10.1109/ISMS.2014.58](https://doi.org/10.1109/ISMS.2014.58). arXiv: [1202.6294v2](https://arxiv.org/abs/1202.6294v2) (vid. pág. 34).
- [76] P. Ortiz y M. Matas. “Experiences about Fusioning 3d Digitalization Techniques for Cultural Heritage Documentation”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 38.5W1 (2006), págs. 224-229 (vid. pág. 16).
- [77] Gintautas Palubinskas y Peter Reinartz. “Multi-Resolution, Multi-Sensor Image Fusion: General Fusion Framework”. En: *2011 Joint Urban Remote Sensing Event, JURSE 2011 - Proceedings*. IEEE, abr. de 2011, págs. 313-316. DOI: [10.1109/JURSE.2011.5764782](https://doi.org/10.1109/JURSE.2011.5764782) (vid. pág. 34).
- [78] Anthony Pamart et al. “Toward a Data Fusion Index for the Assessment and Enhancement of 3D Multimodal Reconstruction of Built Cultural Heritage”. En: *Remote Sensing* 15.9 (mayo de 2023), pág. 2408. DOI: [10.3390/rs15092408](https://doi.org/10.3390/rs15092408) (vid. pág. 26).
- [79] Giacomo Patrucco et al. “3D Data Fusion for Historical Analyses of Heritage Buildings Using Thermal Images: The Palacio de Colomina as a Case Study”. En: *Remote Sensing* 14.22 (nov. de 2022), pág. 5699. DOI: [10.3390/rs14225699](https://doi.org/10.3390/rs14225699) (vid. págs. 21, 116).
- [80] Roberto Pierdicca et al. “Point Cloud Semantic Segmentation Using a Deep Learning Framework for Cultural Heritage”. En: *Remote Sensing* 12.6 (mar. de 2020), pág. 1005. DOI: [10.3390/rs12061005](https://doi.org/10.3390/rs12061005) (vid. págs. 21, 22).
- [81] Danae Phaedra Pocobelli et al. “BIM for Heritage Science: A Review”. En: *Heritage Science* 6.1 (2018). DOI: [10.1186/s40494-018-0191-4](https://doi.org/10.1186/s40494-018-0191-4) (vid. pág. 7).
- [82] G Polzlbauer. “Survey and Comparison of Quality Measures for Self-Organizing Maps”. En: *Proceedings of the fifth workshop on Data Analysis (WDA04)* (2004), págs. 67-82 (vid. pág. 127).
- [83] Florent Poux y Roland Billen. “Voxel-Based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods”. En: *ISPRS International Journal of Geo-Information* 8.5 (mayo de 2019), pág. 213. DOI: [10.3390/ijgi8050213](https://doi.org/10.3390/ijgi8050213) (vid. págs. 23, 86).
- [84] Florent Poux et al. “3D Point Clouds in Archaeology: Advances in Acquisition, Processing and Knowledge Integration Applied to Quasi-Planar Objects”. En: *Geosciences (Switzerland)* 7.4 (sep. de 2017), pág. 96. DOI: [10.3390/geosciences7040096](https://doi.org/10.3390/geosciences7040096) (vid. pág. 86).

- [85] Florent Poux et al. “3D Point Clouds in Archaeology: Advances in Acquisition, Processing and Knowledge Integration Applied to Quasi-Planar Objects”. En: *Geosciences* 7.4 (sep. de 2017), pág. 96. DOI: [10.3390/geosciences7040096](https://doi.org/10.3390/geosciences7040096) (vid. pág. 116).
- [86] Caterina Previato et al. “A Multi-Scalar Approach for the Study of Ancient Architecture: Structure for Motion, Laser Scanning and Direct Survey of the Roman Theatre of Nora (Cagliari, Sardinia)”. En: *Journal of Archaeological Science: Reports* 43 (jun. de 2022), pág. 103440. DOI: [10.1016/j.jasrep.2022.103440](https://doi.org/10.1016/j.jasrep.2022.103440) (vid. pág. 5).
- [87] B. Quintana et al. “Door Detection in 3D Coloured Point Clouds of Indoor Environments”. En: *Automation in Construction* 85 (ene. de 2018), págs. 146-166. DOI: [10.1016/j.autcon.2017.10.016](https://doi.org/10.1016/j.autcon.2017.10.016) (vid. pág. 86).
- [88] Javier Raimundo et al. “Super Resolution Infrared Thermal Imaging Using Pansharpening Algorithms: Quantitative Assessment and Application to Uav Thermal Imaging”. En: *Sensors (Switzerland)* 21.4 (2021), págs. 1-18. DOI: [10.3390/s21041265](https://doi.org/10.3390/s21041265) (vid. págs. 48, 53, 81, 83).
- [89] Javier Raimundo et al. “Multisensor Data Fusion by Means of Voxelization: Application to a Construction Element of Historic Heritage”. En: *Remote Sensing* 14.17 (ago. de 2022), pág. 4172. DOI: [10.3390/rs14174172](https://doi.org/10.3390/rs14174172) (vid. pág. 91).
- [90] M. M. Ramos y F. Remondino. “Data Fusion in Cultural Heritage – A Review”. En: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-5/W7 (ago. de 2015), págs. 359-363. DOI: [10.5194/isprsarchives-XL-5-W7-359-2015](https://doi.org/10.5194/isprsarchives-XL-5-W7-359-2015) (vid. págs. 21, 24, 25, 116).
- [91] Thierry Ranchin y Lucien Wald. “Fusion of High Spatial and Spectral Resolution Images: The ARSIS Concept and Its Implementation”. En: *Photogrammetric Engineering and Remote Sensing* 66.1 (2000), págs. 49-61 (vid. pág. 57).
- [92] M. L.L. Reiss et al. “Data Integration Acquired from Micro-UAV and Terrestrial Laser Scanner for the 3D Mapping of Jesuit Ruins of São Miguel Das Missões”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 41.June (2016), págs. 315-321. DOI: [10.5194/isprsarchives-XLI-B5-315-2016](https://doi.org/10.5194/isprsarchives-XLI-B5-315-2016) (vid. pág. 25).
- [93] Ignacio Rocco Spremolla et al. “RGB-D and Thermal Sensor Fusion - Application in Person Tracking”. En: *Proceedings of the 11th Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*. SCITEPRESS - Science and Technology Publications, 2016, págs. 610-617. DOI: [10.5220/0005717706100617](https://doi.org/10.5220/0005717706100617) (vid. pág. 30).
- [94] C. Rodríguez-Moreno et al. “From Point Cloud to BIM: An Integrated Workflow for Documentation, Research and Modelling of Architectural Heritage”. En: *Survey Review* 50.360 (2018), págs. 212-231. DOI: [10.1080/00396265.2016.1259719](https://doi.org/10.1080/00396265.2016.1259719). arXiv: [1011.1669v3](https://arxiv.org/abs/1011.1669v3) (vid. pág. 7).
- [95] Francesca Rosi et al. “6. Recent Trends in the Application of Fourier Transform Infrared (FT-IR) Spectroscopy in Heritage Science: Frommicro- to Non-Invasive FT-IR”. En: *Chemical Analysis in Cultural Heritage*. Ed. por Luigia Sabbatini e Inez Dorothé Van Der Werf. De Gruyter, feb. de 2020, págs. 121-150. DOI: [10.1515/9783110457537-006](https://doi.org/10.1515/9783110457537-006) (vid. pág. 123).

- [96] Ethan Rublee et al. “ORB: An Efficient Alternative to SIFT or SURF”. En: *2011 International Conference on Computer Vision*. Barcelona, Spain: IEEE, nov. de 2011, págs. 2564-2571. DOI: [10.1109/ICCV.2011.6126544](https://doi.org/10.1109/ICCV.2011.6126544) (vid. pág. 54).
- [97] M. Scaioni et al. “Integration of Infrared Thermography & Photogrammetric Surveying of Built Landscape”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives 42.5W1* (mayo de 2017), págs. 153-160. DOI: [10.5194/isprs-Archives-XLII-5-W1-153-2017](https://doi.org/10.5194/isprs-Archives-XLII-5-W1-153-2017) (vid. pág. 29).
- [98] N. Senin, B.M. Colosimo y M. Pacella. “Point Set Augmentation through Fitting for Enhanced ICP Registration of Point Clouds in Multisensor Coordinate Metrology”. En: *Robotics and Computer-Integrated Manufacturing* 29.1 (feb. de 2013), págs. 39-52. DOI: [10.1016/j.rcim.2012.07.003](https://doi.org/10.1016/j.rcim.2012.07.003) (vid. pág. 87).
- [99] S. Sfarra et al. “Infrared Exploration of the Architectural Heritage: From Passive Infrared Thermography to Hybrid Infrared Thermography (HIRT) Approach”. En: *Materiales de Construcción* 66.323 (2016), e094. DOI: [10.3989/mc.2016.07415](https://doi.org/10.3989/mc.2016.07415) (vid. pág. 18).
- [100] Hamid Reza Shahdoosti. “MS and PAN Image Fusion by Combining Brovey and Wavelet Methods”. En: *arXiv* (2017) (vid. pág. 35).
- [101] Andreas A. Sidiropoulos, Konstantinos N. Lakakis y Vasiliki K.Mouza. “PCA-based Localization of Pathology on Heritage Building Masonry”. En: *International Journal of Constructive Research in Civil Engineering* 2.3 (2016). DOI: [10.20431/2454-8693.0203001](https://doi.org/10.20431/2454-8693.0203001) (vid. pág. 38).
- [102] A. Sledz, J. Unger y C. Heipke. “Thermal IR Imaging: Image Quality and Orthophoto Generation”. En: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives 42.1* (sep. de 2018), págs. 413-420. DOI: [10.5194/isprs-archives-XLII-1-413-2018](https://doi.org/10.5194/isprs-archives-XLII-1-413-2018) (vid. pág. 32).
- [103] Hyojoo Son y Changwan Kim. “Automatic Segmentation and 3D Modeling of Pipelines into Constituent Parts from Laser-Scan Data of the Built Environment”. En: *Automation in Construction* 68 (ago. de 2016), págs. 203-211. DOI: [10.1016/j.autcon.2016.05.010](https://doi.org/10.1016/j.autcon.2016.05.010) (vid. pág. 87).
- [104] Brandon Stark, Brendan Smith y Yangquan Chen. “Survey of Thermal Infrared Remote Sensing for Unmanned Aerial Systems”. En: *2014 International Conference on Unmanned Aircraft Systems, ICUAS 2014 - Conference Proceedings*. 2014, págs. 1294-1299. DOI: [10.1109/ICUAS.2014.6842387](https://doi.org/10.1109/ICUAS.2014.6842387) (vid. págs. 28, 29).
- [105] Pavel Stefanovič y Olga Kurasova. “Visual Analysis of Self-Organizing Maps”. En: *Nonlinear Analysis: Modelling and Control* 16.4 (dic. de 2011), págs. 488-504. DOI: [10.15388/NA.16.4.14091](https://doi.org/10.15388/NA.16.4.14091) (vid. pág. 130).
- [106] Efstratios Stylianidis y Fabio Remondino. “3D Recording”. En: *Leshono Suryoyo: First Studies in Syriac*. Ed. por Efstratios Stylianidis y Fabio Remondino. Caithness: Gorgias Press, dic. de 2005, págs. XIII-xiv. DOI: [10.31826/9781463210113-002](https://doi.org/10.31826/9781463210113-002) (vid. pág. 7).
- [107] Efstratios Stylianidis y Fabio Remondino, eds. *3D Recording, Documentation and Management of Cultural Heritage*. Caithness, Scotland, UK: Whittles Publishing, 2016 (vid. págs. 2, 20, 115).
- [108] Simone Teruggi et al. “A Hierarchical Machine Learning Approach for Multi-Level and Multi-Resolution 3D Point Cloud Classification”. En: *Remote Sensing* 12.16 (ago. de 2020), pág. 2598. DOI: [10.3390/rs12162598](https://doi.org/10.3390/rs12162598) (vid. pág. 116).

- [109] K. Themistocleous et al. “The Methodology of Documenting Cultural Heritage Sites Using Photogrammetry, UAV, and 3D Printing Techniques: The Case Study of Asinou Church in Cyprus”. En: *Third International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2015)*. Ed. por Diofantos G. Hadjimitsis et al. Vol. 9535. Jun. de 2015, pág. 953510. DOI: [10.1117/12.2195626](https://doi.org/10.1117/12.2195626) (vid. pág. 7).
- [110] Jose Alberto Torres-Martínez et al. “Combining Geometrical and Radiometrical Features in the Evaluation of Rock Art Paintings”. En: *Digital Applications in Archaeology and Cultural Heritage* 5 (2017), págs. 10-20. DOI: [10.1016/j.daach.2017.04.001](https://doi.org/10.1016/j.daach.2017.04.001) (vid. pág. 26).
- [111] José Antonio Huesca Tortosa et al. “The Façade of the Church of Nuestra Señora de La Asunción in Biar (Spain): From Point Cloud to HBIM”. En: *WIT Transactions on the Built Environment*. Vol. 169. Mayo de 2017, págs. 69-77. DOI: [10.2495/BIM170071](https://doi.org/10.2495/BIM170071) (vid. pág. 7).
- [112] Trong Phuc Truong et al. “Registration of RGB and Thermal Point Clouds Generated by Structure from Motion”. En: *Proceedings - 2017 IEEE International Conference on Computer Vision Workshops, ICCVW 2017*. Vol. 2018-Janua. IEEE, oct. de 2017, págs. 419-427. DOI: [10.1109/ICCVW.2017.57](https://doi.org/10.1109/ICCVW.2017.57) (vid. pág. 29).
- [113] Te Ming Tu et al. “A New Look at IHS-like Image Fusion Methods”. En: *Information Fusion* 2.3 (sep. de 2001), págs. 177-186. DOI: [10.1016/S1566-2535\(01\)00036-7](https://doi.org/10.1016/S1566-2535(01)00036-7) (vid. pág. 51).
- [114] Darren Turner et al. “Spatial Co-Registration of Ultra-High Resolution Visible, Multispectral and Thermal Images Acquired with a Micro-UAV over Antarctic Moss Beds”. En: *Remote Sensing* 6.5 (mayo de 2014), págs. 4003-4024. DOI: [10.3390/rs6054003](https://doi.org/10.3390/rs6054003) (vid. pág. 25).
- [115] Sebastian Tuttas et al. “Acquisition and Consecutive Registration of Photogrammetric Point Clouds for Construction Progress Monitoring Using a 4D BIM”. En: *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 85.1 (feb. de 2017), págs. 3-15. DOI: [10.1007/s41064-016-0002-z](https://doi.org/10.1007/s41064-016-0002-z) (vid. pág. 85).
- [116] Enrique Valero, Frédéric Bosché y Alan Forster. “Automatic Segmentation of 3D Point Clouds of Rubble Masonry Walls, and Its Application to Building Surveying, Repair and Maintenance”. En: *Automation in Construction* 96 (2018), págs. 29-39. DOI: [10.1016/j.autcon.2018.08.018](https://doi.org/10.1016/j.autcon.2018.08.018) (vid. pág. 21).
- [117] Veeraraghavan Vijayaraj, C.G. O’Hara y N.H. Younan. “Quality Analysis of Pansharpened Images”. En: *IEEE International IEEE International IEEE International Geoscience and Remote Sensing Symposium, 2004. IGARSS ’04. Proceedings. 2004*. Vol. 1. IEEE, 2004, págs. 85-88. DOI: [10.1109/IGARSS.2004.1368951](https://doi.org/10.1109/IGARSS.2004.1368951) (vid. págs. 34, 56).
- [118] Gemine Vivone et al. “A Critical Comparison among Pansharpening Algorithms”. En: *IEEE Transactions on Geoscience and Remote Sensing* 53.5 (mayo de 2015), págs. 2565-2586. DOI: [10.1109/TGRS.2014.2361734](https://doi.org/10.1109/TGRS.2014.2361734) (vid. pág. 34).
- [119] L. Wald y T. Ranchin. “Liu ’Smoothing Filter-Based Intensity Modulation: A Spectral Preserve Image Fusion Technique for Improving Spatial Details”. En: *International Journal of Remote Sensing* 23.3 (2002), págs. 593-597. DOI: [10.1080/01431160110088772](https://doi.org/10.1080/01431160110088772) (vid. pág. 52).

- [120] Lucien Wald. “Quality of High Resolution Synthesised Images: Is There a Simple Criterion ?” En: *Third conference "Fusion of Earth data: merging point measurements, raster maps and remotely sensed images"* (2000), págs. 99-103 (vid. pág. 57).
- [121] Lucien Wald, Thierry Ranchin y Marc Mangolini. “Fusion of Satellite Images of Different Spatial Resolutions: Assessing the Quality of Resulting Images”. En: *Photogrammetric Engineering and Remote Sensing* 63.6 (1997), págs. 691-699 (vid. pág. 55).
- [122] Chao Wang, Yong K. Cho y Mengmeng Gai. “As-Is 3D Thermal Modeling for Existing Building Envelopes Using a Hybrid LIDAR System”. En: *Journal of Computing in Civil Engineering* 27.6 (nov. de 2013), págs. 645-656. DOI: [10.1061/\(ASCE\)CP.1943-5487.0000273](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000273) (vid. pág. 18).
- [123] Qian Wang y Min-Koo Kim. “Applications of 3D Point Cloud Data in the Construction Industry: A Fifteen-Year Review from 2004 to 2018”. En: *Advanced Engineering Informatics* 39 (ene. de 2019), págs. 306-319. DOI: [10.1016/j.aei.2019.02.007](https://doi.org/10.1016/j.aei.2019.02.007) (vid. págs. 84, 85).
- [124] Zhou Wang y Alan C. Bovik. “A Universal Image Quality Index”. En: *IEEE Signal Processing Letters* 9.3 (2002), págs. 81-84. DOI: [10.1109/97.995823](https://doi.org/10.1109/97.995823) (vid. pág. 58).
- [125] Xuehan Xiong et al. “Automatic Creation of Semantically Rich 3D Building Models from Laser Scanner Data”. En: *Automation in Construction* 31 (mayo de 2013), págs. 325-337. DOI: [10.1016/j.autcon.2012.10.006](https://doi.org/10.1016/j.autcon.2012.10.006) (vid. pág. 86).
- [126] Yusheng Xu, Xiaohua Tong y Uwe Stilla. “Voxel-Based Representation of 3D Point Clouds: Methods, Applications, and Its Potential Use in the Construction Industry”. En: *Automation in Construction* 126. February (jun. de 2021), pág. 103675. DOI: [10.1016/j.autcon.2021.103675](https://doi.org/10.1016/j.autcon.2021.103675) (vid. págs. 84-87).
- [127] Yusheng Xu et al. “Reconstruction of Scaffolds from a Photogrammetric Point Cloud of Construction Sites Using a Novel 3D Local Feature Descriptor”. En: *Automation in Construction* 85 (ene. de 2018), págs. 76-95. DOI: [10.1016/j.autcon.2017.09.014](https://doi.org/10.1016/j.autcon.2017.09.014) (vid. pág. 87).
- [128] Reda Yaagoubi y Yehia Miky. “Developing a Combined Light Detecting And Ranging (LiDAR) and Building Information Modeling (BIM) Approach for Documentation and Deformation Assessment of Historical Buildings”. En: *MATEC Web of Conferences* 149 (feb. de 2018). Ed. por A. Diouri et al., pág. 02011. DOI: [10.1051/mateconf/201814902011](https://doi.org/10.1051/mateconf/201814902011) (vid. pág. 7).
- [129] Ming-Der Yang, Tung-Ching Su y Hung-Yu Lin. “Fusion of Infrared Thermal Image and Visible Image for 3D Thermal Model Reconstruction Using Smartphone Sensors”. En: *Sensors* 18.7 (jun. de 2018), pág. 2003. DOI: [10.3390/s18072003](https://doi.org/10.3390/s18072003) (vid. pág. 29).
- [130] Naoto Yokoya. “Texture-Guided Multisensor Superresolution for Remotely Sensed Images”. En: *Remote Sensing* 9.4 (mar. de 2017), pág. 316. DOI: [10.3390/rs9040316](https://doi.org/10.3390/rs9040316) (vid. pág. 57).
- [131] Linwei Yue et al. “Image Super-Resolution: The Techniques, Applications, and Future”. En: *Signal Processing* 128 (nov. de 2016), págs. 389-408. DOI: [10.1016/j.sigpro.2016.05.002](https://doi.org/10.1016/j.sigpro.2016.05.002) (vid. págs. 32, 48).
- [132] Qian-Yi Zhou, Jaesik Park y Vladlen Koltun. “Open3D: A Modern Library for 3D Data Processing”. En: (ene. de 2018). DOI: [10.48550/arXiv.1801.09847](https://doi.org/10.48550/arXiv.1801.09847). arXiv: [1801.09847](https://arxiv.org/abs/1801.09847) (vid. pág. 93).

- [133] Luis Caballero Zoreda et al. *Notas Sobre El Complejo Productivo de Melque (Toledo): : Prospección Del Territorio y Análisis de Carbono 14, Polínicos, Carpológicos y Antracológicos y de Morteros*. Inf. téc. Archivo español de arqueología - Consejo Superior de Investigaciones Científicas, 1999 (vid. pág. [120](#)).

*Il semble que la perfection soit atteinte non quand il n'y a plus rien à ajouter, mais quand il n'y a plus rien à retrancher.*

Parece que la perfección se alcanza no cuando no hay nada más que añadir, sino cuando no hay nada más que retirar.

ANTOINE DE SAINT-EXUPERY (1900-1944).