



Escola Politècnica Superior  
d'Edificació de Barcelona

UNIVERSITAT POLITÈCNICA DE CATALUNYA

# INGENIERÍA TÉCNICA TOPOGRÁFICA

## PROYECTO FINAL DE CARRERA

### CLASIFICACIÓN MULTIESPECTRAL DE IMÁGENES DIGITALES EN EL ÁMBITO ARQUITECTÓNICO

**Proyectista:** Santiago Martínez Cañaveras

**Director:** Felipe Buill Pozuelo

**Convocatoria:** Junio 2013



## **RESUMEN**

En este proyecto se describen una serie de técnicas de clasificación utilizadas en el ámbito de la teledetección aplicadas al patrimonio arquitectónico. Se establece una metodología para este tipo de proyectos y su aplicación para obtener cartografía temática.

El objetivo principal es llevar a cabo la clasificación a partir de imágenes multiespectrales obtenidas con una cámara estándar modificada, de la cual podemos obtener cuatro canales de información (3 canales de color y un canal infrarrojo cercano), a diferencia de la teledetección satelital en la que se llegan a utilizar muchas bandas del espectro electromagnético (más de siete canales de información) para realizar la extracción de información cualitativa, conocida por clasificación multiespectral. Se utiliza también otro tipo de imagen digital obtenida con cámara térmica, que remuestreada y ajustada a la imagen de color original permite una imagen de cinco canales para ser utilizada en el proceso de clasificación.

Como objetivo derivado, la aplicación de la metodología propuesta a varios casos de estudio para su validación.



# ÍNDICE

1	INTRODUCCIÓN .....	- 1 -
2	IMAGEN DIGITAL .....	- 2 -
2.1	RGB. MODELO DE COLOR.....	- 2 -
2.2	MÉTODOS DE ADQUISICIÓN .....	- 2 -
3	METODOLOGÍA E INSTRUMENTACIÓN .....	- 4 -
3.1	TOMA DE DATOS .....	- 4 -
3.2	INSTRUMENTACIÓN .....	- 4 -
	EQUIPO FOTOGRAFICO .....	- 4 -
	EQUIPO INFORMÁTICO .....	- 5 -
3.3	PREPROCESAMIENTO .....	- 6 -
3.4	CLASIFICACIÓN .....	- 7 -
	CLASIFICACIÓN NO SUPERVISADA.....	- 7 -
	CLASIFICACIÓN SUPERVISADA .....	- 7 -
	CLASIFICACIÓN POR MÍNIMA DISTANCIA.....	- 8 -
	CLASIFICACIÓN POR PARALELEPÍPEDOS.....	- 9 -
	CLASIFICACIÓN DE MÁXIMA VEROSIMILITUD.....	- 10 -
	ÁREAS DE ENTRENAMIENTO .....	- 11 -
	ERROR DE CLASIFICACIÓN.....	- 12 -
	POSTCLASIFICACIÓN.....	- 12 -
4	APLICACIONES.....	- 14 -
4.1	CONVENCIONAL .....	- 14 -
4.2	PATRIMONIO .....	- 14 -
5	CASOS DE ESTUDIO.....	- 17 -
5.1	ARQUITECTURA DE GAUDÍ .....	- 17 -
	PORTERÍA PARQUE GÜELL .....	- 17 -
	PUERTA GÜELL.....	- 20 -
5.2	MURALLA DE BARCELONA .....	- 26 -
6	CONCLUSIONES / RECOMENDACIONES.....	- 30 -
7	BIBLIOGRAFÍA .....	- 31 -
	AGRADECIMIENTOS .....	- 32 -



## 1 INTRODUCCIÓN

Las aplicaciones no cartográficas de la fotogrametría son muy variadas y utilizadas desde hace mucho tiempo (Buill, 2008), sin embargo las aplicaciones efectuadas con la teledetección, en este campo, son menos conocidas y utilizadas, fundamentalmente por la falta de cámaras multiespectrales para el caso terrestre, de resolución media y coste no elevado. En este proyecto se muestran una serie de trabajos desarrollados con una cámara estándar modificada para que pueda capturar información infrarroja cercana. Además se ha incorporado en un caso un canal infrarrojo medio obtenido con una cámara de imagen térmica.

En el proyecto se presentan procedimientos utilizados en la teledetección aplicados al campo del patrimonio arquitectónico, de manera análoga a cómo se realiza el caso fotogramétrico terrestre.

Se puede definir *Teledetección* como la técnica que permite obtener información a distancia de objetos sin que exista un contacto material, en este caso de objetos situados sobre la superficie terrestre (Lillesand, 2007).

*Fotogrametría* es el conjunto de técnicas que permiten obtener información de objetos físicos y del medio ambiente mediante procesos de registro, medición e interpretación de imágenes fotográficas y de modelos de energía radiante electromagnética y de otros fenómenos (Wolf, 1999).

A partir de esta definición, pueden diferenciarse dos áreas posibles de trabajo: la fotogrametría métrica y la fotogrametría interpretativa. La fotogrametría métrica se encarga de obtener medidas precisas a partir de fotografías o imágenes digitales. Por otro lado, la fotogrametría interpretativa trata principalmente de reconocer e identificar objetos y realizar un análisis sistemático y cuidadoso de los mismos.

El *tratamiento digital de imágenes* se fundamenta en dos áreas principales de aplicación: la mejora de la información pictórica para la interpretación humana y el procesamiento de los datos de la escena para la percepción autónoma por una máquina (González, 1996).

Aplicando las técnicas de teledetección y fotogrametría interpretativa seremos capaces de capturar y obtener datos espaciales y, mediante los procesos de tratamiento digital de imágenes, obtener cartografía temática de elementos arquitectónicos y arqueológicos, que es la finalidad de este proyecto.

## 2 IMAGEN DIGITAL

El término *imagen* se refiere a una función bidimensional de intensidad de luz  $f(x,y)$ , donde  $x$  e  $y$  representan las coordenadas espaciales y el valor de  $f$  en un punto cualquiera  $(x,y)$  es proporcional al nivel de gris de la imagen en ese punto.

Una *imagen digital* es una imagen  $f(x,y)$  que se ha discretizado tanto en las coordenadas espaciales como en brillo. Una imagen digital puede considerarse como una matriz cuyos índices de fila y columna identifican un punto de la imagen y el valor correspondiente de la matriz indica el nivel de gris en ese punto. Los elementos de una distribución digital de este tipo se denominan píxeles.

### 2.1 RGB. MODELO DE COLOR

Un modelo de color es la especificación de un sistema de coordenadas tridimensional y de un subespacio de este sistema en el que cada color queda representado por un único punto.

Las imágenes del modelo de color RGB consisten en tres planos de imagen independientes, uno por cada color primario (figura 1). Cuando llegan a un monitor RGB, estas imágenes se combinan en la pantalla para producir una imagen en color compuesta.




Figura 1: Representación de los tres planos de color  
Imagen extraída de [multimediaintegral.com](http://multimediaintegral.com)

### 2.2 MÉTODOS DE ADQUISICIÓN

La radiación electromagnética es una forma de energía que se propaga mediante ondas que se desplazan por el espacio a la velocidad de la luz transportando cantidades discretas de energía. Estas ondas se caracterizan por tener longitudes diferentes. El conjunto de todas las longitudes de onda se denomina espectro electromagnético.



Para realizar una observación se necesita una interacción entre el objeto y el sensor. En este caso, la interacción va a ser un flujo de radiación que parte de los objetos y se dirige al sensor. Los sensores se dividen en dos categorías: sensores activos y sensores pasivos. En el primer caso, la escena es irradiada por un emisor, y un receptor registra la luminancia difundida por la escena. En el caso de los sensores pasivos las fuentes utilizadas son las naturales, en nuestro caso, la del Sol.




Figura 2: Espectro electromagnético  
Imagen extraída de [www.um.es](http://www.um.es)

Cualquier objeto en la naturaleza emite radiación y lo hace con diferentes longitudes de onda. Tanto la cantidad de energía que emite un cuerpo por la radiación como la distribución de esta energía en diferentes longitudes de onda, depende fundamentalmente del tipo de material y la temperatura de dicho cuerpo. La radiación solar domina aquellas regiones del espectro electromagnético que corresponden a la radiación visible y al infrarrojo reflejado. Por lo tanto, estos serán los cuatro canales con los que trabajaremos en este proyecto. Obtendremos tres imágenes para la radiación visible (Rojo, Verde y Azul) y una imagen para el infrarrojo reflejado.

### **3 METODOLOGÍA E INSTRUMENTACIÓN**

En este capítulo se van a describir unos métodos de clasificación que no siempre van a resultar útiles para obtener los resultados deseados. Es por ello que se mostrarán los tipos de clasificación que se han probado, y cuál ha sido su resultado. Si el resultado no es satisfactorio o no es el esperado, podremos descartar ese método.

#### **3.1 TOMA DE DATOS**

Los datos necesarios para llevar a cabo el análisis se obtienen directamente en el lugar donde se quiere realizar la clasificación. Estos datos son principalmente las imágenes digitales multiespectrales (visible e infrarrojo cercano). Además de las imágenes, realizamos anotaciones referentes a la hora del día en que se tomaron las imágenes, las condiciones meteorológicas del momento, materiales de la zona y otros datos que nos permitan analizar más tarde si las fotografías obtenidas son útiles para realizar la clasificación.

#### **3.2 INSTRUMENTACIÓN**

Los instrumentos que hemos empleado para llevar a cabo el proyecto son:

- Equipo fotográfico y complementos (Cámara digital, filtros, ...)
- Equipo informático (Con software para la clasificación de imágenes)

El equipo fotográfico y el equipo informático pertenecen al Laboratorio de Fotogrametría de la Escola Politècnica Superior d'Edificació de Barcelona.

#### **EQUIPO FOTOGRAFICO**

Para la captura de imágenes en el espectro visible se utilizó una cámara digital modificada con filtro RGB y para la toma en infrarrojo, únicamente se cambió el filtro RBG por un filtro infrarrojo.

Dicha cámara está modificada al eliminarse el filtro situado delante del sensor para que pudiera ser sensible a la luz infrarroja.

En todo momento, la toma de fotografías se realizó sobre un trípode, teniendo absoluto cuidado de no moverlo en el cambio de filtros.

Características de la cámara:

- Canon EOS 450D modificada
- Cámara digital réflex monocular con AF/AE
- Sensor: CMOS grande de placa única
- Tamaño de imagen: 4272 x 2848 píxeles
- Píxeles: 12,40 megapíxeles (12,20 megapíxeles efectivos)
- Soporte de grabación: Tarjeta de memoria SD

Características de los filtros de gelatina:

- Diámetro: 77mm.
- Filtro Infrarrojo: Schneider Optics B+W 093
- Filtro Color: Schneider Optics B+W 486

El filtro infrarrojo modelo B+W 093 bloquea todo el espectro visible y por lo tanto al ojo humano se ve completamente opaco. Esto crea una fotografía infrarroja pura, eliminando el componente rojo visible. Su transmisión comienza a partir de los 800 nm, aumentando hasta los 900 nm, y sigue aumentando más allá del límite superior de la sensibilización cubierta por las películas de infrarrojos. Este filtro se utiliza con menos frecuencia en la fotografía pictórica debido a la dramática pérdida de la norma ISO efectiva, pero en el campo científico, de investigación, el análisis forense y de materiales, la limitación a un rango estrictamente infrarrojo es a menudo importante.



Sin filtro

Con filtro

Figura 3: Diferencia entre una imagen con filtro infrarrojo y una sin.  
Imagen extraída de Schneider Optics

El filtro de color modelo B+W 486 tiene un soporte de vidrio completamente incoloro compuesto por distintas capas muy finas, que reflejan parcialmente las longitudes de onda que no pertenecen al rango visible. Este tipo de filtro no bloquea por medio de la absorción, sino que esas finas capas reflejan repetidamente la radiación ultravioleta e infrarroja.



Figura 4: Filtro infrarrojo y filtro de color.  
Imagen extraída de Schneider Optics

## EQUIPO INFORMÁTICO

El análisis y clasificación se realizó en el laboratorio de Fotogrametría en un PC con procesador I7 y con sistema operativo Windows 7, con el software de análisis de imágenes ENVI 4.3 y el software de rectificación de imágenes RDF.

### 3.3 PREPROCESAMIENTO

Antes de comenzar con el propio análisis, se deben realizar un conjunto de tareas previas a la aplicación del método. En nuestro caso, las tareas que hemos realizado han sido: elección de la mejor toma, remuestreo de la imagen y extracción de las zonas de interés.

Para la elección de la mejor toma es el operario el que decide las que son aptas para realizar la posterior clasificación. La imagen que se muestra en la Figura 5 ha sido descartada debido a un reflejo de luz:



Figura 5: Ejemplo de fotografía descartada

Las fotografías se realizaron siguiendo siempre el mismo orden, primero las fotografías con el filtro de color y con el filtro infrarrojo posteriormente. El cambio de filtro puede provocar ligeros movimientos en la cámara, por lo que esas imágenes no servirían para la clasificación. El desplazamiento no es apreciable en la vista previa de la cámara pero sí al combinar las 4 bandas en una sola imagen. Es por eso que debemos hacer un remuestreo de la imagen infrarroja a partir de unos puntos de control para hacerla coincidir con las 3 bandas del visible. Remuestrear una imagen también es necesario cuando trabajamos con imágenes tomadas con distintas cámaras o tomadas en dos épocas distintas. Por mucho que intentemos aproximar la posición de la cámara a la de la primera toma, el punto de vista no será el mismo, por ello debemos rectificar la imagen y remuestrearla después

Finalmente, para acabar de preparar la imagen para el proceso de clasificación, realizamos un recorte a la imagen para extraer y quedarnos únicamente con la zona que queremos trabajar, eliminando así zonas que no queremos que aparezcan como edificios colindantes o zonas de cielo descubierta. El software utilizado nos permite recortar las 4 bandas en un solo paso:



Figura 6: Imagen original e imagen recortada

### 3.4 CLASIFICACIÓN

La clasificación multiespectral de imágenes se basa en la utilización de algoritmos que etiquetan los píxeles de las imágenes en clases o categorías, y que pueden corresponderse con objetos del mundo real. La clasificación multiespectral es un caso particular del problema general de clasificar  $N$  individuos en un conjunto de  $K$  clases en función de una serie de variables  $(X_1, X_2, \dots, X_n)$ . Para resolver este problema se realiza un análisis para medir la semejanza o diferencia entre los diferentes individuos. Dos individuos muy parecidos pertenecerán con toda seguridad a la misma clase, mientras que dos individuos distintos pertenecerán a diferentes clases. La medida más utilizada es la distancia euclidiana:

$$d_{i,j} = \sqrt{\sum_{v=1}^n (X_{vi} - X_{vj})^2}$$

Al no saber con certeza a que clase corresponde cada uno de los píxeles, el problema de la clasificación se convierte en un problema de probabilidad, por lo tanto se suelen usar métodos estadísticos. Hay dos pasos a realizar en la clasificación: Generación de clases y adjudicación de los píxeles a alguna de las clases. Existen dos métodos para afrontar el problema de generación de clases:

- Partir de clases previamente definidas (Clasificación supervisada)
- No establecer ninguna clase (Clasificación no supervisada)

#### **CLASIFICACIÓN NO SUPERVISADA**

Se utilizan algoritmos de clasificación automática multivariante. Este procedimiento consta de  $N$  pasos siendo  $N$  el número total de individuos a clasificar. En cada paso se identifican los dos individuos más próximos, se hace una clase con ellos y se sustituyen por el centroide de la clase resultante. De este modo cada paso analiza un individuo menos que el anterior ya que los individuos van siendo sustituidos por clases. El proceso se detiene cuando se ha alcanzado un número de clases igual al número de clases que había sido establecido a priori. Por lo tanto debemos elegir previamente el número de clases que queremos, este número debe ser elevado ya que siempre podremos a posteriori unir aquellas clases que no tenga sentido mantener separadas.

Durante el transcurso de este proyecto y después de haber realizado numerosas pruebas, la clasificación no supervisada resultó no ser útil al presentar unos resultados muy diferentes a los esperados. Las clases generadas no correspondían a una clasificación de materiales.

#### **CLASIFICACIÓN SUPERVISADA**

La clasificación supervisada se basa en la creación de áreas de entrenamiento. Estas deben ser áreas lo más homogéneas posibles y en las que sepamos qué tipo de material es el que estamos asignando a esa clase. Una clase puede estar formada por más de un área de entrenamiento, pero no a la inversa. El software asigna un valor a cada clase que viene dado por la respuesta espectral media de los píxeles. Sin embargo, puesto que hemos creado las reseñas espectrales con varios píxeles de una misma clase, lo que obtenemos no es un único valor en el que a cada banda se le asigna un valor de reflectividad, sino una

distribución de reflectividades para cada banda con una serie de estadísticos (media, desviación típica, máximo, mínimo, etc.).

Para entender mejor los conceptos básicos de la clasificación y los diferentes métodos, vamos a suponer que disponemos solo de dos bandas de color (Azul y Rojo) para realizar la clasificación. Los píxeles representados gráficamente con tres colores diferentes corresponden a tres clases obtenidas a partir de las áreas de entrenamiento:

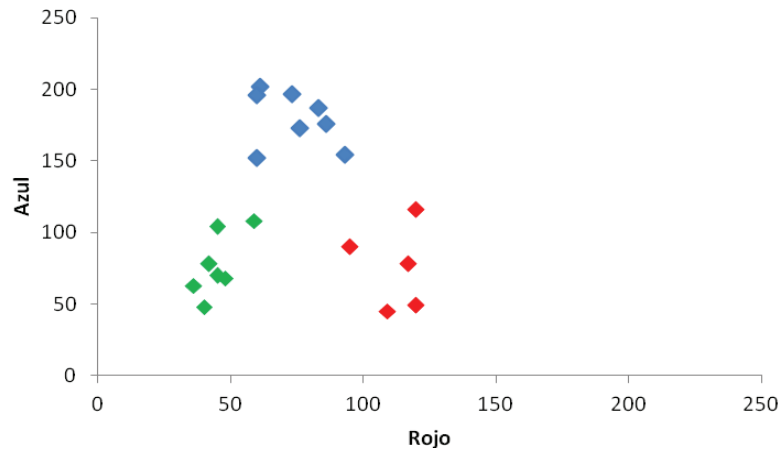


Figura 7: Distribución de los píxeles de las áreas de entrenamiento

Una vez se dispone del conjunto de clases y de sus reseñas espectrales, hay que adjudicar cada uno de los píxeles de la imagen a una clase. Para ello existen varios procedimientos. Los que hemos probado para realizar el proyecto son:

- Clasificación por mínima distancia
- Clasificación por paralelepípedos
- Clasificación de máxima verosimilitud

### **CLASIFICACIÓN POR MÍNIMA DISTANCIA**

Puesto que cada clase dispone de una reflectividad media para cada una de las bandas, podemos situar cada una de las clases como un centroide en un espacio de variables. En este espacio de variables se puede calcular la distancia entre un píxel y una clase. Evidentemente, un píxel X se asignará a la clase respecto a la cual su distancia sea mínima.




Figura 8: Clasificación por mínima distancia

Este método no es demasiado bueno ya que sobreclasifica la imagen, es decir ningún píxel queda sin clasificar. En el caso práctico, esto se traduce en mucho ruido y confusión de clases, por lo que este método quedó descartado para las clasificaciones de este proyecto.

### CLASIFICACIÓN POR PARALELEPÍEDOS

En este método se definen una serie de paralelepípedos que definen las fronteras de cada clase. La definición de cada uno de los paralelepípedos debe hacerse teniendo en cuenta los valores máximos y mínimos de reflectividad para cada una de las bandas.

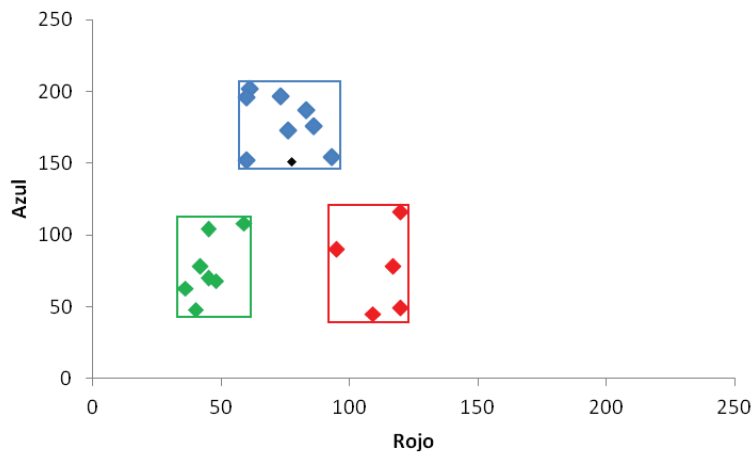


Figura 9: Clasificación por paralelepípedos

Con este método pueden aparecer píxeles sin asignar o píxeles que podrían ser asignados a varias clases. En el caso práctico, nuestras pruebas dieron lugar a que hubiera clases definidas por el usuario que no aparecían en la clasificación. Este método pues, también fue descartado para realizar las clasificaciones.

## CLASIFICACIÓN DE MÁXIMA VEROSIMILITUD

Puesto que se tiene la media y la desviación típica de cada una de las clases, se puede utilizar algún modelo de distribución de probabilidad. El clasificador de máxima probabilidad asume que los datos siguen una función de distribución normal para asignar la probabilidad de que un píxel cualquiera pertenezca a cada una de las clases. El píxel se asigna de este modo a la clase a la que es más probable que pertenezca.

Este método puede usarse de forma automática, o el usuario puede establecer algún criterio que permita asignar píxeles a una clase sólo si la probabilidad correspondiente es superior a determinado umbral. En el caso práctico, puesto que tenemos imágenes de gran resolución, se decidió que el programa asignara una clase al píxel, siempre y cuando la probabilidad de que ese píxel pertenezca a esa clase sea superior al 80%.

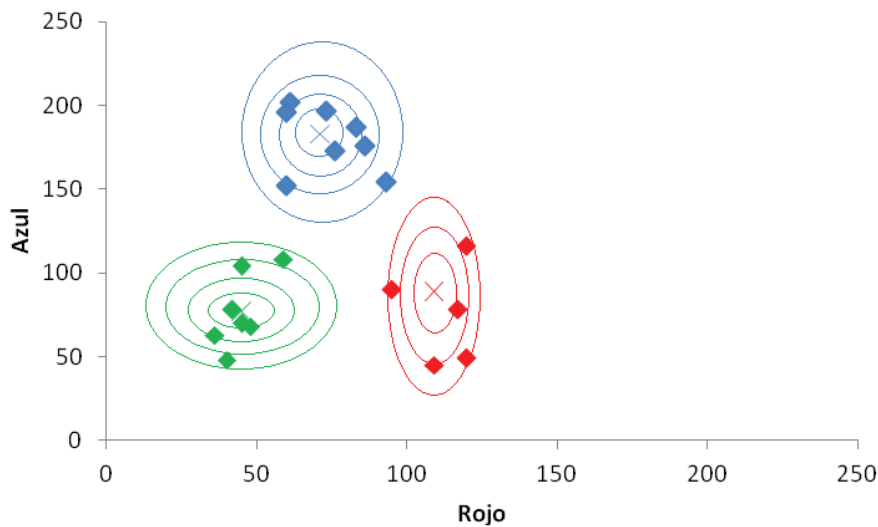


Figura 10: Clasificación de máxima verosimilitud

En la Figura 8 aparecen una serie de elipses rodeando a cada uno de los centroides, se trata de líneas de *isoprobabilidad*, por tanto el píxel se clasificará como perteneciente a la clase en la que sus valores resulten más probables. En el caso práctico, este tipo de clasificación fue el que mejores resultados obtenía. Por lo tanto, después de realizar diversas pruebas, este es el método que escogí para realizar las clasificaciones de las diferentes fotografías del proyecto.

En resumen, tras haber probado los distintos métodos de clasificación podemos concluir que:

- La clasificación no supervisada puede darnos una idea del número de clases que podríamos definir para la clasificación supervisada, pero no puede considerarse un método para la clasificación de materiales.
- La clasificación supervisada por el método de mínima distancia no resulta útil del todo básicamente por una razón. Al asignar a todos los píxeles una clase, se pueden clasificar píxeles que no deberían ser incluidos en ninguna clase. Otros métodos nos permiten crear una clase nula pero, en este caso, aunque el píxel no tenga nada que ver con ninguna clase, el software lo asignará a la que más se le parezca (a la que al distancia sea menor). Esta clasificación, no será válida para la realización de este proyecto.



- Viendo el diagrama de la clasificación supervisada por el método de los paralelepípedos, es fácil imaginar porqué ha sido descartado para nuestro proyecto. Aunque un píxel quede muy cerca del área de un paralelepípedo, si no está contenido en éste, el píxel pasará a pertenecer a la clase nula. En las pruebas realizadas, siempre había una gran cantidad de píxeles en la clase nula, reduciendo así la calidad de la clasificación y obligando a descartar este método como válido.
- La clasificación supervisada por el método de máxima verosimilitud resultó ser la que mejores resultados mostraba. Además de obtener un alto grado de acierto, el programa nos permite asignar el porcentaje de probabilidad de que un píxel pertenezca a una clase. En fotografías de poca calidad, este porcentaje no debería ser muy alto, pues una gran cantidad de píxeles quedarían asignados a la clase nula. La resolución de nuestras fotografías nos permiten asignar un porcentaje mayor, de entre un 80% y un 85%, dependiendo de la fotografía. La clasificación supervisada de máxima verosimilitud será, por su alto porcentaje de acierto y calidad de clasificación, la que utilizemos en este proyecto.

## ÁREAS DE ENTRENAMIENTO

Para la creación de las áreas de entrenamiento hay que tener en cuenta básicamente dos aspectos, la homogeneidad de las clases y los factores externos reflejados en la fotografía. En clases heterogéneas hay que seleccionar un mayor número de muestras de entrenamiento repartidas por la imagen, de modo que aumente la muestra de píxeles de esa clase. En clases homogéneas, los datos pueden tener menor número de píxeles. Por otro lado, los datos extraídos de una muestra del mundo real están afectados por factores muy diversos, como por ejemplo la forma del objeto, la iluminación exterior, la textura, etc. Para evitar esta variabilidad y provocar una incorrecta asignación, se crea un mayor número de clases y posteriormente se reagrupa las clases fragmentadas.



Figura 11: Áreas de entrenamiento

En la figura 11 podemos ver cómo las clase correspondiente al color blanco y marrón, debería ser la misma, pero los factores externos han deteriorado parte de los pilares blancos. En este caso, se ha optado por fragmentar la clase en dos y posteriormente, si se quisiera, se podrían reagrupar ambas en una sola clase.

## ERROR DE CLASIFICACIÓN

Existen dos posibilidades, evaluar una estimación teórica del error en función de las características del algoritmo de clasificación o analizar una serie de áreas test obtenidas del mismo modo que las áreas de entrenamiento. El segundo modo de proceder permite obtener una estimación más realista de los errores así que fue el método escogido para analizar el error. Es importante que las áreas de entrenamiento que utilizamos para analizar el error de clasificación sean diferentes de las primeras áreas de entrenamiento.

Un método simple y apropiado de evaluaciones de los errores es utilizar la matriz de confusión de clases:

Class	Ground Truth (Pixels)						Total	% Accuracy
	Ladrillo	Vegetacion	Metal	Suelo	Piedra1	Piedra2		
Ladrillo [Red]	55570	554	46	0	274	10329	66773	83.22
Vegetacion [Green]	914	71965	0	0	14	591	73484	97.93
Metal [Black]	1698	0	88722	0	11704	13539	115663	76.71
Suelo [Cyan]	0	0	0	65161	9139	72	74372	87.61
Piedra1 [Blue]	20	0	0	0	90469	15590	106079	85.28
Piedra2 [Yellow]	5037	300	110	0	4714	38622	48783	79.17
Total	63239	72819	88878	65161	116314	78743	485154	

Figura 12: Matriz de confusión con 6 clases


En la Figura 12 aparece un ejemplo de matriz de confusiones. Los valores en filas representan las clases reales y en las columnas (Las que aparecen acompañadas por su color) las clases obtenidas tras la clasificación. Por tanto debe interpretarse como el número de píxeles que perteneciendo a la clase "fila" han sido adjudicados a la clase "columna". En la parte derecha de la tabla aparece el número total de píxeles de cada clase, y el porcentaje de píxeles clasificados correctamente para cada clase.

Para un correcto análisis he subrayado en verde las celdas donde los valores deberían ser más altos (Los píxeles han estado asignados correctamente a su clase). En una perfecta clasificación el valor del resto de celdas debería ser igual a 0.


## POSTCLASIFICACIÓN

Cuando obtenemos la imagen clasificada, se puede aumentar la calidad de la misma aplicando técnicas especiales de postclasificación. En concreto, se utilizará un filtro *Majority Analysis*. Este filtro examina los píxeles de una matriz de tamaño especificada por el usuario, y le asigna al píxel central el valor correspondiente al que pertenezca la mayoría de valores de la matriz. El tamaño de matriz utilizado para las imágenes de este proyecto fue de 11x11 y, en algunos casos 15x15.


En la figura 13 podemos apreciar cómo la aplicación de este filtro, nos ayuda a eliminar gran parte del *ruido* creado en la clasificación. Las imágenes (a) y (c) muestran una imagen clasificada y una zona al detalle. En las imágenes (b) y (d) una imagen clasificada a la que se le ha aplicado un filtro *Majority Analysis*.




(a)



(b)



(c)



(d)

Figura 13: *Majority Analysis*

## 4 APLICACIONES

### 4.1 CONVENCIONAL

El término *aplicaciones convencionales* hace referencia a las aplicaciones efectuadas en el campo de la teledetección satelital. El software que utilizamos está pensado para el análisis de imágenes satelitales. Las imágenes obtenidas mediante satélite proporcionan muchos más canales de información que las fotografías terrestres. En una imagen obtenida desde satélite podemos trabajar con siete bandas, con unas longitudes de onda más amplias que las que se utilizan en este proyecto. La ventaja principal al disponer de más canales de información es que permite realizar clasificaciones más cuidadas de tipo de vegetación, hidrografía, cultivos, etc. En la figura 14 se muestra un ejemplo de clasificación de una imagen satélite.





Figura 14: Clasificación de una imagen satélite  
Imagen extraída de irrigación.gov.ar

### 4.2 PATRIMONIO

La clasificación aplicada al caso terrestre está menos desarrollada y es en la que se centra este proyecto, en concreto en el patrimonio arquitectónico. La finalidad de obtener una cartografía sobre fachadas arquitectónicas puede ir desde la restauración hasta la simple documentación de las características del elemento que quiere cartografiarse. La cartografía del patrimonio va más allá del patrimonio arquitectónico, podemos encontrar aplicaciones en otros campos como:

➤ Arqueología




Figura 15: Clasificación en el ámbito de la arqueología  
Imagen extraída de gifle.webs.upv.es

➤ Patrimonio cultural




Figura 16: Clasificación en el ámbito del patrimonio cultural  
Imagen extraída de gifle.webs.upv.es

➤ Recuperación de pinturas rupestres




Figura 17: Clasificación en el ámbito de las pinturas rupestres  
Imagen extraída de dstrech.com

La recuperación de pinturas románicas para su posterior clasificación ha sido un área en la que también hemos llegado a realizar pruebas, pero no disponíamos del material suficiente para ser desarrollado en este proyecto.




Figura 17: Prueba realizada de recuperación de información de pinturas románicas, Iglesia de Sant Pere, Terrassa

La aplicación en el patrimonio arquitectónico es la que queremos mostrar en una serie de casos que serán detallados en el siguiente capítulo.

## 5 CASOS DE ESTUDIO

### 5.1 ARQUITECTURA GAUDÍ

La elección de la arquitectura de Antoni Gaudí para la aplicación de esta metodología de clasificación es debido a la diversidad de materiales que el arquitecto utilizaba en sus obras. Metal, cerámica, ladrillo y otros materiales son los que vamos a intentar clasificar en dos de sus obras, la Puerta Güell y el pabellón destinado a la portería del Parque Güell.

#### PORTERÍA PARQUE GÜELL

➤ Localización



Figura 17: Localización geográfica del caso de estudio  
Imagen extraída de icc.cat

➤ Zona de estudio

El primer caso de estudio se encuentra en el Park Güell (Parque Güell), un espacio público con jardines y muchos elementos arquitectónicos de Antoni Gaudí situado en la parte superior de la ciudad de Barcelona. Está situado en la vertiente que mira al mar de la montaña del Carmelo. En la figura 18 se muestra una imagen de la fachada en la que vamos a realizar la clasificación. La imagen corresponde a la fachada interior del pabellón que fue destinado a la portería de la entrada del Parque Güell. Debajo de la imagen a color se muestra la imagen de cada una de las bandas que se utilizaron para la clasificación.



Figura 18: Primer caso de estudio

En este caso, no hizo falta realizar una clasificación no supervisada, puesto que los materiales representados en la fotografía eran bastante reconocibles. Las seis clases correspondientes a los materiales fueron las siguientes: Madera [Rojo], Piedra [Amarillo], Cerámica [Blanco], Metal [Azul], Vegetación [Verde] y la clase nula *Unclassified* [Negro].

Antes de realizar la clasificación por el método de máxima verosimilitud, se realizó una mediante el método de distancia mínima. El resultado es evidentemente incorrecto por las causas que hemos explicado anteriormente. En la figura 19 podemos ver a la izquierda la clasificación realizada con el método de mínima distancia y a la derecha realizada con el método de máxima verosimilitud:



Figura 19: Método de mínima distancia y de máxima verosimilitud



Para acabar el proceso de clasificación, aplicaremos el filtro *majority analysis* para eliminar el ruido y conseguir un resultado más limpio de la clasificación. Además se genera la matriz de error y calcula el porcentaje de precisión general (*Overall Accuracy*). Como podemos observar en la siguiente figura, con el filtro *majority analysis*, no sólo conseguimos una mejora visual, sino que esa mejora se ve reflejada en la matriz de error, así como en el porcentaje de precisión general. En el Anexo se pueden encontrar las estadísticas completas del error de la clasificación.




Figura 20: Clasificación antes y después de aplicar el filtro *majority analysis*

Overall Accuracy =	(630382/694379)		90,7836%				
Ground Truth (Pixels)							
Class	Madera	Piedra	Ceramica	Metal	Vegetacion	Total	% Accuracy
Unclassified	8	7083	4127	970	4270	16458	
Madera [Red]	18858	11636	0	4157	0	34651	72.33
Piedra [Yellow]	2689	308283	270	3938	8	315188	90.63
Ceramica [White]	0	609	114126	1370	0	116105	91.80
Metal [Blue]	4516	12367	20	6210	0	23113	37.31
Vegetacion [Green]	0	183	3	0	40054	40240	90.35
Total	26071	340161	124319	16645	44332	694379	

Figura 21: Matriz de error antes de aplicar el filtro *majority analysis*

Overall Accuracy =	(574890/600840)		95,6810%				
Ground Truth (Pixels)							
Class	Piedra	Ceramica	Madera	Vegetacion	Metal	Total	% Accuracy
Piedra [Yellow]	236534	121	0	0	3097	239752	95.79
Ceramica [White]	0	113618	0	0	0	113618	91.40
Madera [Red]	1068	0	26071	0	1719	28858	90.34
Vegetacion [Green]	99	0	0	44298	0	44397	99.92
Metal [Blue]	9227	0	0	0	11518	20745	70.52
Total	246941	124311	26071	44332	16334	600840	

Figura 22: Matriz de error después de aplicar el filtro *majority analysis*

## PUERTA GÜELL

➤ Localización

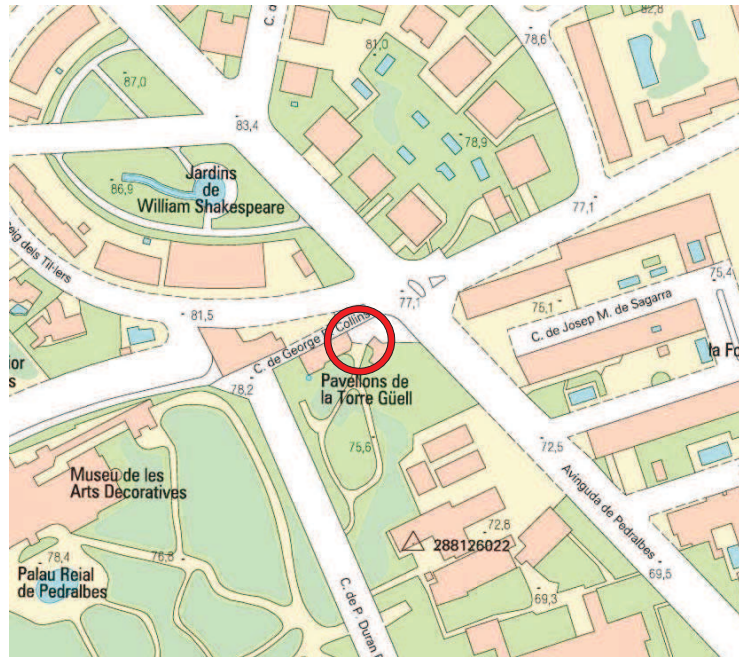


Figura 23: Localización geográfica del caso de estudio  
Imagen extraída de icc.cat

El segundo caso de estudio de la arquitectura de Gaudí corresponde a la entrada de los Pabellones Güell, una serie de edificaciones situadas en el barrio de Pedralbes en Barcelona, construidos entre 1884 y 1887. La entrada está compuesta por una puerta de forja de hierro con forma de dragón que une las dos fachadas que vamos a estudiar. La fachada lateral derecha pertenece a la edificación destinada a la portería y la fachada lateral izquierda pertenece a una de las cuatro paredes de las caballerizas de los Pabellones Güell. Cada una de las tres zonas de estudio (fachada lateral izquierda, puerta y fachada lateral derecha) serán estudiadas aisladamente, aunque en el caso de las fachadas laterales, la representación de las distintas clases será la misma. La zona de estudio de la puerta tendrá distinta representación puesto que está compuesta por otro tipo de materiales. En la figura 24 podemos ver una imagen de las tres zonas de estudio.



Figura 24: Zonas de estudio de la puerta Güell

## ➤ Fachada lateral derecha

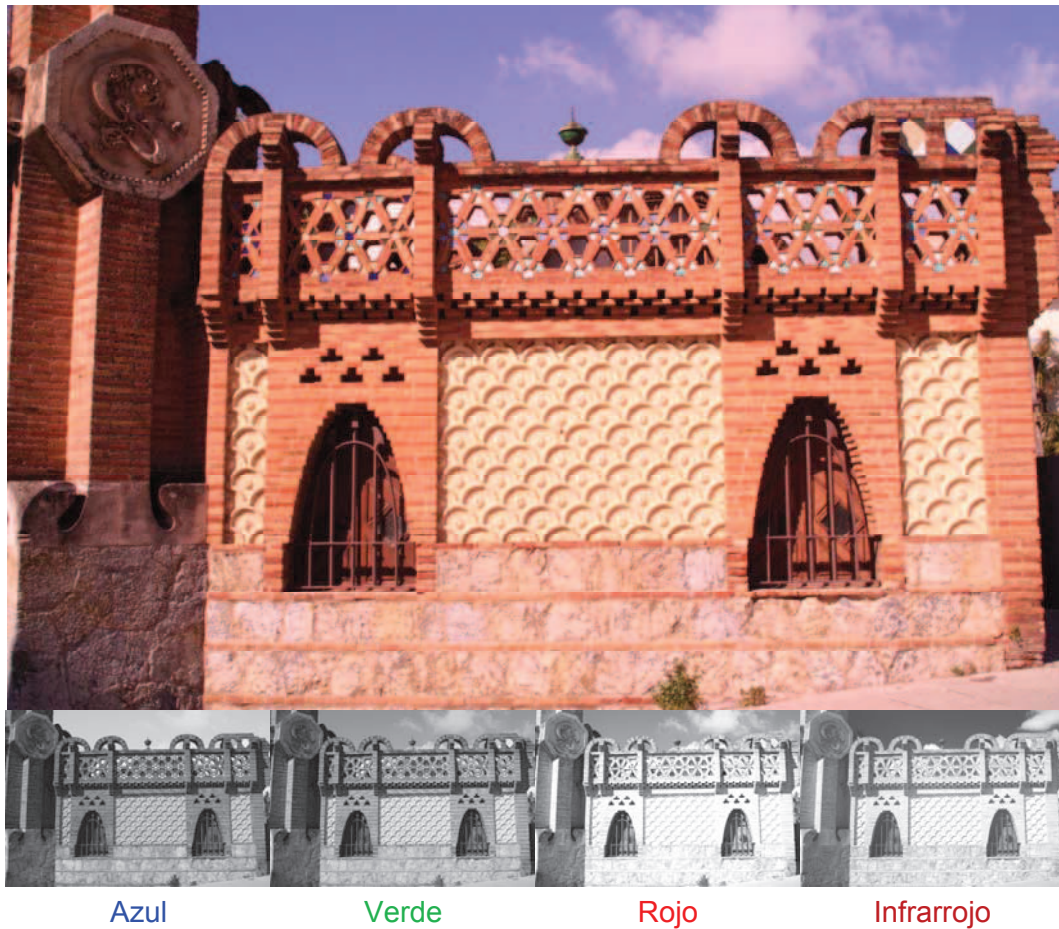


Figura 25: Segundo caso de estudio. Fachada lateral derecha

Como ya hemos comentado anteriormente, para los casos de estudio de arquitectura de Gaudí, no realizaremos rectificaciones de las fotografías. Para esta fachada hemos considerado las siguientes clases: Ladrillo [Rojo], Vegetación [Verde], Piedra1 [Azul], Piedra2 [Amarillo], Piedra3 [Cian], Metal [Magenta] y Madera [Marrón]. De ahora en adelante mostraremos las clasificaciones con el filtro *majority analysis* ya aplicado.




Figura 26: Clasificación fachada lateral derecha

Overall Accuracy=	(688823/789372)	87,2622%										
Ground Truth (Pixels)												
Class	Ladrillo	Vegetacion	Piedra1	Piedra2	Piedra3	Metal	Madera	Total	% Accuracy			
Ladrillo [Red]	264533	181	1917	11310	2299	19	502	280761	77.84			
Vegetacion [Green]	712	4341	35	0	0	0	0	5088	95.93			
Piedra1 [Blue]	37363	3	106806	166	244	2016	0	146598	97.22			
Piedra2 [Yellow]	13722	0	38	201015	2309	0	0	217084	93.00			
Piedra3 [Cyan]	23276	0	475	3657	100399	0	0	127807	95.39			
Metal [Magenta]	216	0	591	0	0	11729	0	12536	85.22			
Madera [Maroon]	59967	0	1122	2821	0	240	34375	98525	98.56			
Total	339822	4525	109862	216148	105251	13764	34877	824249				

Figura 27: Matriz de error de Fachada lateral derecha

En este caso, el porcentaje de precisión general es menor que el anterior. Aun así es aceptable, ya que nosotros partíamos con la premisa de clasificar píxeles con una probabilidad superior al 85%.

➤ Puerta




Figura 28: Segundo caso de estudio. Puerta

En el estudio de la puerta se llevaron a cabo 2 pruebas, la primera se realizó con 6 clases y la segunda con 8 clases. Con este aumento en el número de clases se pretendía analizar si el incremento de clases mejoraba la calidad de la clasificación, o si por el contrario, lo empeoraba. Para el caso de la clasificación con 6 clases, éstas fueron: Ladrillo [Rojo], Vegetación [Verde], Metal [Negro], Piedra1 [Azul], Piedra2 [Amarillo] y Suelo [Cian]. Para el segundo caso, añadimos las clases Arena [Coral] y Cielo [Blanco].




Figura 29: Clasificación Puerta

A simple vista podemos observar como el hecho de añadir las dos clases ha hecho que perdamos casi por completo la clase Piedra2 [Amarillo] y se cree más confusión en la clase Ladrillo [Rojo]. Estas diferencias se trasladan a la matriz de error de forma que en la columna Ladrillo y en la columna Piedra2 existan valores altos de coincidencia con otras clases a parte de la suya propia. Además en el porcentaje de precisión general se ve claramente como la precisión de la clasificación ha disminuido:

Overall Accuracy =	(410509/485154)		84,6142%						
	Ground Truth (Pixels)								
Class	Ladrillo	Vegetacion	Metal	Suelo	Piedra1	Piedra2	Total	% Accuracy	
Ladrillo [Red]	55570	554	46	0	274	10329	66773	87.87	
Vegetacion [Green]	914	71965	0	0	14	591	73484	98.83	
Metal [Black]	1698	0	88722	0	11704	13539	115663	99.82	
Suelo [Cyan]	0	0	0	65161	9139	72	74372	100.00	
Piedra1 [Blue]	20	0	0	0	90469	15590	106079	77.78	
Piedra2 [Yellow]	5037	300	110	0	4714	38622	48783	49.05	
Total	63239	72819	88878	65161	116314	78743	485154		

Figura 30: Matriz de error de Puerta con 6 clases

Comparando ambas matrices, podemos ver que el porcentaje de acierto en la clase Piedra2 ha pasado del 49,05% al 24,41%. Y en la clase Ladrillo, el porcentaje de acierto ha disminuido de 87,87% a 66,02% tal y como podíamos intuir al ver las clasificaciones. En el resto de clases la diferencia no es tan grande, pero sí ha habido una ligera disminución. Estas disminuciones conllevan que del 84,61% de acierto total en la clasificación con 6 clases pase a ser del 77,88% en la clasificación con 8 clases.

Overall Accuracy =	(424072/544480)											77,8857%
Ground Truth (Pixels)												
Class	Ladrillo	Vegetacion	Metal	Suelo	Piedra1	Piedra2	Arena	Cielo	Total	% Accuracy		
Ladrillo [Red]	41753	3163	0	0	20	5446	640	0	51022	66.02		
Vegetacion [Green]	1094	68608	0	0	36	23	2	0	69763	94.22		
Metal [Black]	5583	339	87394	0	9356	16525	1033	0	120230	98.33		
Suelo [Purple]	0	0	0	64795	16311	263	0	0	81369	99.44		
Piedra1 [Blue]	1445	46	286	366	84783	21312	0	0	108238	72.89		
Piedra2 [Yellow]	3112	454	1107	0	5052	19221	133	0	29079	24.41		
Arena [Coral]	4869	120	91	0	746	14700	9252	0	29778	83.65		
Cielo [White]	5383	89	0	0	10	1253	0	48266	55001	100.00		
Total	63239	72819	88878	65161	116314	78743	11060	48266	544480			

Figura 31: Matriz de error de Puerta con 8 clases

Cabe destacar que no siempre el hecho de crear más clases conlleve una disminución de la calidad de clasificación. En el siguiente ejemplo volveremos a crear 8 clases y veremos si el resultado es más satisfactorio o verdaderamente el hecho de crear más clases conlleva una peor clasificación.

➤ Fachada lateral izquierda



Figura 32: Segundo caso de estudio. Fachada lateral izquierda

En este caso, volvimos a hacer una clasificación con 8 clases (se hacen 8 clases porque la diversidad de materiales lo permite). En este caso las clases que se han creado han sido las siguientes: Ladrillo [Rojo], Piedra1 [Azul], Piedra2 [Amarillo], Piedra3 [Cian], Piedra4 [Magenta], Madera [Marrón], Metal [Negro] y Vegetación [Verde].




Figura 33: Clasificación fachada lateral izquierda

Los tipos de materiales son muy parecidos a los que se encontraban en la fachada lateral derecha, es por eso que las clases son tan parecidas. La única diferencia es que hemos incluido una clase más de piedra, Piedra4. Con la matriz de error comprobaremos si al añadir una clase más hemos empeorado la clasificación o no.

Overall Accuracy =	(561786/665348)		84,4349%									
Class	Ground Truth (Pixels)								Total	% Accuracy		
	Ladrillo	Piedra1	Piedra2	Piedra3	Piedra4	Madera	Metal	Vegetacion				
Ladrillo [Red]	107879	1006	20	989	2343	2892	0	0	115129	91.71		
Piedra1 [Blue]	0	90680	0	2477	307	0	0	0	93464	78.86		
Piedra2 [Yellow]	19	0	154148	8	1638	0	0	93	155906	99.98		
Piedra3 [Cyan]	2621	10620	0	66106	29565	794	0	0	109706	68.48		
Piedra4 [Magenta]	3732	12452	0	26937	24402	0	101	791	68415	41.56		
Madera [Maroon]	2395	236	0	21	0	32192	0	0	34844	89.73		
Metal [Black]	874	0	0	0	0	0	16747	0	17621	99.06		
Vegetacion [Green]	113	0	4	0	456	0	58	69632	70263	98.75		
Total	117633	114994	154172	96538	58711	35878	16906	70516	665348			

Figura 34: Matriz de error de Fachada lateral derecha

El porcentaje en la precisión general de esta clasificación no ha variado demasiado respecto al de la otra fachada con una clase menos. Sí es verdad que el porcentaje de acierto de la clase Piedra4 es el más bajo respecto a las otras clases, hay que destacar que ese tipo de piedra ha dado problemas en el resto de clasificaciones y si observamos ese tipo de piedra en otras clasificaciones podremos comprobar que el porcentaje de acierto es el más pequeño respecto el del resto de clases.

## 5.2 MURALLA DE BARCELONA

Se ha trabajado también en un paño de la muralla romana de Barcelona ya que se disponía de este elemento fotografías efectuadas con una cámara térmica. En este caso se quiere estudiar la posibilidad de generar imágenes multispectrales desde diferentes sensores y ver su aprovechamiento.

### ➤ Localización




Figura 35: Localización geográfica del caso de estudio  
Imagen extraída de icc.cat

El trozo de la antigua muralla romana de Barcelona sobre el que vamos a trabajar está situado en uno de los patios de la escuela Sant Felip Neri. Dicho patio se encuentra en el Carrer de la Palla cerca de la Catedral de Barcelona en el barrio Gótico.

### ➤ Zona de estudio

La segunda muralla romana de Barcelona fue construida entre los siglos II y IV para sustituir a otra muralla de menos grueso y altura. Durante todos estos siglos, la muralla ha sufrido los estragos del tiempo, además de las modificaciones llevadas a cabo por el hombre. En este caso intentaremos ver si el tratamiento de las fotografías nos permite apreciar esos cambios además de realizar una clasificación como hemos hecho en los casos anteriores. Una diferencia entre este caso y el resto, será que dispondremos de un canal más de información. Una imagen térmica nos permitirá comparar si añadiendo un canal de información adicional podemos mejorar nuestra clasificación y obtener datos que no hubiéramos podido conseguir con 4 canales.





Figura 36: Tercer caso de estudio

Como hemos comentado anteriormente, para este caso vamos a disponer de un quinto canal de información. La imagen térmica que tenemos para incluirla en el análisis ha sido tomada por una cámara diferente en una época diferente y en una posición diferente. Es por eso que tendremos que rectificar y remuestrear las imágenes que hemos tomado de la muralla. La imagen térmica ya está rectificada, por lo que no será necesario transformarla.




Figura 36: Imagen térmica de la muralla

La rectificación de la imagen puede hacerse a partir de puntos de control del terreno o como en nuestro caso, a partir de las coordenadas imagen de la fotografía térmica. Con el software de rectificación de imágenes *RDF* hemos realizado la rectificación de las cuatro imágenes obtenidas en campo y el resultado ha sido el siguiente:




Figura 37: Las 5 bandas remuestreadas

Como se puede observar, el área sobre la que se va a trabajar es menor que el área fotografiada. El tamaño de la imagen infrarroja térmica ha condicionado que tengamos que trabajar en una zona más reducida de la que se pretendía.

Para realizar esta clasificación optamos primero por realizar una no supervisada de 5 clases. El resultado de ésta mostraba una serie de sillares que clasificaba diferente de otros sillares de alrededor. Este hecho hizo que tuviéramos en cuenta que no todos tenían que ir dentro de una misma clase.




Figura 38: Clasificación no supervisada de la muralla



## 6 CONCLUSIONES / RECOMENDACIONES

Una vez llevado a cabo las diferentes pruebas en los diferentes casos de estudio, podemos concluir que:

- Es posible realizar una clasificación utilizando únicamente cuatro canales de información. Es cierto que no es una clasificación del todo completa, pero para aplicaciones arquitectónicas puede resultar bastante útil.
- Podemos aumentar la calidad de una clasificación añadiendo otro canal de información. En nuestro caso, hemos añadido una banda con una imagen térmica.
- Podemos realizar una clasificación con imágenes de distintas cámaras, de distintas épocas y realizadas desde un punto de vista diferente. Con la metodología que se describe en este proyecto podemos realizar una serie de tratamientos a la imagen y conseguir que parezcan tomadas desde el mismo punto de vista y compartan la misma resolución.
- A medida que se realizaban pruebas en los distintos casos de estudio, hemos podido establecer una metodología para obtener una clasificación óptima. Los pasos a realizar son los siguientes:
  - Rectificación/ortoproyección y remuestreo para obtener imágenes ortogonales a la fachada, necesarias si las fotografías han sido tomadas con distintas cámaras o distinta posición.
  - Realizar una clasificación no supervisada como paso inicial para tener una idea del número de clases que se pueden crear en la clasificación supervisada.
  - Crear una clasificación supervisada con el método de máxima verosimilitud con el número de clases conveniente. Es muy importante realizar una correcta distribución de las áreas de entrenamiento.
  - Si fuera necesario, añadir o eliminar una o más clases en función del resultado obtenido en el paso anterior.
  - Una vez obtenida la clasificación efectuar un tratamiento del resultado aplicando un suavizado, en nuestro caso el filtro *majority analysis* para optimizar el resultado.
  - Calcular la matriz de error de la clasificación para dar ésta por válida. Si alguna clase diera demasiado error, podría modificarse las áreas de entrenamiento y repetir el proceso de clasificación.

## 7 BIBLIOGRAFÍA

Buill, F., Núñez, M. A. y Rodríguez, J. J. (2008), Fotogrametría arquitectónica, Volumen 55 de Aula d'Arquitectura, Edit. Univ. Politèc. de Catalunya.

González, R.C.; Woods, R.E. Tratamiento digital de imágenes. Edición en español de la obra Digital Image Processing. Delaware, 1996. Addison-Wesley Iberoamericana S.A.

Lerma, J.L. (1999), Metodología de clasificación multispectral de imágenes digitales para el reconocimiento y caracterización de materiales y patologías en fachadas arquitectónicas. Tesis doctoral, UPV, Departamento de Ingeniería Cartográfica, Geodesia y Fotogrametría.

Lillesand, M., Kiefer, R. W. and Chipman, J. (2007) Remote Sensing and Image Interpretation, 6th Edition, Editors John Wiley & Sons.

Wolf, P. i DeWitt , B. (1999), Elements of Photogrammetry with Applications in GIS. Ed. McGraw-Hill Education.

Universidad de Murcia. SIGMUR. [Página en línea], <http://www.um.es>

GIFLE. Grupo de Investigación de Fotogrametría y Láser Escáner. Departamento de Ingeniería Cartográfica, Geodesia y Fotogrametría de la Universidad Politécnica de Valencia. [Página en línea], <http://gifle.webs.upv.es>

## **AGRADECIMIENTOS**

En primer lugar agradecer al director del proyecto Felipe Buill, profesor del Departamento de Ingeniería del Terreno, Cartográfica y Geofísica de la Escuela Politécnica Superior de Edificación de Barcelona, por haber dedicado su tiempo y esfuerzo para que este proyecto tuviera forma.

A la EPSEB de la Universidad Politécnica de Cataluña, por prestarme el material necesario para llevar a cabo el proyecto.

A Carol Puig, profesora de Teledetección en la Escuela Politécnica Superior de Edificación de Barcelona, por orientarme en la manera de realizar clasificaciones.

A Mónica Aznar y Valeria Cid por acompañarme y ayudarme en los trabajos realizados en campo.

Y finalmente, a mis compañeros que han estado trabajando en el Laboratorio de Fotogrametría junto a mí, por su apoyo mostrado durante las semanas de trabajo.







## ANEJO



**ANEJO**

A continuación se muestran las estadísticas de cada clasificación:

**Confusion Matrix: Primer caso de estudio. Parque Güell**

Overall Accuracy = (574890/600840) = 95,6810%

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
Piedra1 [Yellow]	1.34	4.21	3218/239752	10407/246941
Ceramica [White]	0.00	8.60	0/113618	10693/124311
Madera [Red]	9.66	0.00	2787/28858	0/26071
Vegetacion [Green]	0.22	0.08	99/44397	34/44332
Metal [Blue]	44.48	29.48	9227/20745	4816/16334
Nulo [Black]	4.35	0.00	6492/149343	0/142851

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
Piedra1 [Yellow]	95.79	98.66	236534/246941	236534/23975
Ceramica [White]	91.40	100.00	113618/124311	113618/11361
Madera [Red]	100.00	90.34	26071/26071	26071/28858
Vegetacion [Green]	99.92	99.78	44298/44332	44298/44397
Metal [Blue]	70.52	55.52	11518/16334	11518/20745
Nulo [Black]	100.00	95.65	142851/142851	142851/149343

**Confusion Matrix: Segundo caso de estudio. Fachada lateral derecha**

Overall Accuracy = (688823/789372) = 87.2622%

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
Ladrillo [Red]	5.61	22.16	15726/280259	75289/339822
Vegetacion [Green]	14.68	4.07	747/5088	184/4525
Piedra1 [Blue]	27.14	2.78	39792/146598	3056/109862
Piedra2 [Yellow]	7.40	7.00	16069/217084	15133/216148
Piedra3 [Cyan]	21.44	4.61	27408/127807	4852/105251
Metal [Magenta]	6.44	14.78	807/12536	2035/13764

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
Ladrillo [Red]	77.84	94.39	264533/339822	264533/280259
Vegetacion [Green]	95.93	85.32	4341/4525	4341/5088
Piedra1 [Blue]	97.22	72.86	106806/109862	106806/146598
Piedra2 [Yellow]	93.00	92.60	201015/216148	201015/217084
Piedra3 [Cyan]	95.39	78.56	100399/105251	100399/127807
Metal [Magenta]	85.22	93.56	11729/13764	11729/12536

**Confusion Matrix: Segundo caso de estudio. Puerta**

Overall Accuracy = (410509/485154) = 84.6142%

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
Ladrillo [Red]	16.78	12.13	11203/66773	7669/63239
Vegetacion [Green]	2.07	1.17	1519/73484	854/72819
Metal [Black]	23.29	0.18	26941/115663	156/88878
Suelo [Purple]	12.39	0.00	9211/74372	0/65161
Piedra1 [Blue]	14.72	22.22	15610/106079	25845/116314
Piedra2 [Yellow]	20.83	50.95	10161/48783	40121/78743

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
Ladrillo [Red]	87.87	83.22	55570/63239	55570/66773
Vegetacion [Green]	98.83	97.93	71965/72819	71965/73484
Metal [Black]	99.82	76.71	88722/88878	88722/115663
Suelo [Purple]	100.00	87.61	65161/65161	65161/74372
Piedra1 [Blue]	77.78	85.28	90469/116314	90469/106079
Piedra2 [Yellow]	49.05	79.17	38622/78743	38622/48783

**Confusion Matrix: Segundo caso de estudio. Fachada lateral izquierda**

Overall Accuracy = (561786/665348) = 84.4349%

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
Ladrillo [Red]	6.30	8.29	7250/115129	9754/117633
Piedra1 [Blue]	2.98	21.14	2784/93464	24314/114994
Piedra2 [Yellow]	1.13	0.02	1758/155906	24/154172
Piedra3 [Cyan]	39.74	31.52	43600/109706	30432/96538
Piedra4 [Magenta]	64.33	58.44	44013/68415	34309/58711
Madera [Maroon]	7.61	10.27	2652/34844	3686/35878
Metal [Black]	4.96	0.94	874/17621	159/16906
Vegetacion [Green]	0.90	1.25	631/70263	884/70516

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
Ladrillo [Red]	91.71	93.70	107879/117633	107879/115129
Piedra1 [Blue]	78.86	97.02	90680/114994	90680/93464
Piedra2 [Yellow]	99.98	98.87	154148/154172	154148/155906
Piedra3 [Cyan]	68.48	60.26	66106/96538	66106/109706
Piedra4 [Magenta]	41.56	35.67	24402/58711	24402/68415
Madera [Maroon]	89.73	92.39	32192/35878	32192/34844
Metal [Black]	99.06	95.04	16747/16906	16747/17621
Vegetacion [Green]	98.75	99.10	69632/70516	69632/70263

**Confusion Matrix: Tercer caso de estudio. Muralla**

Overall Accuracy = (13051/15479) = 84.3142%

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
Ladrillo [Red]	4.43	32.22	46/1039	472/1465
Vegetacion [Green]	2.37	6.31	18/760	50/792
Piedra1 [Blue]	9.75	40.17	175/1794	1087/2706
Pared [Yellow]	4.75	9.25	160/3369	327/3536
Piedra2 [Coral]	20.63	9.89	533/2584	225/2276
Piedra4 [Maroon]	21.01	3.85	458/2180	69/1791
Piedra3 [Cyan]	19.29	6.80	649/3364	198/2913

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
Ladrillo [Red]	67.78	95.57	993/1465	993/1039
Vegetacion [Green]	93.69	97.63	742/792	742/760
Piedra1 [Blue]	59.83	90.25	1619/2706	1619/1794
Pared [Yellow]	90.75	95.25	3209/3536	3209/3369
Piedra2 [Coral]	90.11	79.37	2051/2276	2051/2584
Piedra4 [Maroon]	96.15	78.99	1722/1791	1722/2180
Piedra3 [Cyan]	93.20	80.71	2715/2913	2715/3364