

**ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y  
ELECTRÓNICA**



**TRABAJO FIN DE GRADO**

**TÉCNICAS DE PROCESADO DE IMÁGENES DE VIDEOVIGILANCIA  
APLICADAS A LA DETECCIÓN DE LLUVIA MEDIANTE  
APRENDIZAJE MÁQUINA**

**Titulación:** Grado en Ingeniería en Tecnologías de la Telecomunicación

**Autor:** Darío Javier Díaz Caballero

**Tutor:** Dr. Juan Luis Navarro Mesa

**Fecha:** Diciembre de 2020



**ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y  
ELECTRÓNICA**



**TRABAJO FIN DE GRADO**

**TÉCNICAS DE PROCESADO DE IMÁGENES DE VIDEOVIGILANCIA  
APLICADAS A LA DETECCIÓN DE LLUVIA MEDIANTE  
APRENDIZAJE MÁQUINA**

**HOJA DE EVALUACIÓN**

**Calificación:** \_\_\_\_\_

**Presidente**

**Secretario/a**

Fdo.: \_\_\_\_\_

Fdo.: \_\_\_\_\_

**Vocal**

Fdo.: \_\_\_\_\_

**Fecha: diciembre 2020**



*Hago una mención especial a mi madre, que desde pequeño me enseñó todos los valores que tenía que aprender para alcanzar mis objetivos. Siempre estuvo ahí, era mi mejor amiga, mi compañera, mi confidente. Siempre intenté seguir el camino que me marcó y ahora se lo dedico a ella, porque se fue con la idea de que sería ingeniero y aquí estoy, a punto de serlo. Gracias por todo lo que significas en mi vida y porque sé que allí donde estés, estarás super orgullosa de mí, Te quiero.*

*Por parte de mi familia, en especial a mi abuela Mamaita que siempre me ha tratado como un hijo, no ha parado de intentar que me vaya bien y darme ese cariño que ha sido fundamental en estos años. También quiero agradecerle a mi tía Yuri y a mi prima Diana, por haber estado siempre ahí, pendiente de mí, intentando ayudarme en todo lo posible.*

*A mis amigos Pedro, Carlos, Ale, Guille, Abián, Dani y Barry, que siempre me han tratado como si fuera de sus familias y se han convertido en esa familia que uno elige.*

*A Lara, que la conocí estudiando esta carrera y se ha convertido en un pilar fundamental en mi vida. Gracias por aguantarme en mis días no tan buenos, estar ahí y enseñarme lo bonito que puede ser querer a una persona.*

*Gracias a todos.*



# Contenido

PARTE I: MEMORIA .....	1
CAPÍTULO 1: INTRODUCCIÓN .....	3
1.1    Introducción.....	3
1.2    Objetivos del Trabajo de Fin de Grado.....	4
1.3    Competencias de la titulación abordadas en el Trabajo de Fin de Título .....	4
1.4    Antecedentes.....	5
1.5    Estructura de la memoria.....	7
CAPÍTULO 2: LA PRECIPITACIÓN.....	8
2.1    Definición de precipitación.....	8
2.2    Formación de la precipitación.....	9
2.3    Clasificación de la precipitación.....	11
2.4    Medidores de la precipitación actuales.....	13
CAPÍTULO 3: LA BASE DE DATOS .....	20
3.1    Captación de los datos .....	20
3.2    Organización de los datos.....	24
CAPÍTULO 4: PREPROCESADO Y EXTRACCIÓN DE CARACTERÍSTICAS DE LA IMAGEN .....	29
4.1    Captura de vídeos .....	29
4.2    Descomposición de imágenes.....	32
4.3    Región de interés .....	32
4.4    Algoritmo Sobel.....	33
CAPÍTULO 5: MARCO METODOLÓGICO PARA LA CLASIFICACIÓN DE LAS IMÁGENES .....	37
5.1    Redes de neuronales convolucionales.....	38
5.2    Redes neuronales recurrentes.....	42
5.3    Redes LSTM.....	44
CAPÍTULO 6: MÉTODO DE DETECCIÓN Y CUANTIFICACIÓN DE PRECIPITACIÓN A PARTIR DE SECUENCIAS DE VÍDEOS.....	49
6.1    Esquema general.....	49
6.2    Preprocesado.....	50
6.3    La Red LSTM.....	56
6.4    Evaluación de resultados .....	60
6.5    Clasificación de los resultados.....	65
6.6    Criterios para realizar los experimentos .....	66
6.7    Experimentos de detección y cuantificación. Resultados.....	69
CAPÍTULO 7: IMPLEMENTACIÓN DEL MÉTODO DE DETECCIÓN Y CUANTIFICACIÓN .....	72
CAPÍTULO 8: RESULTADOS FINALES DE LOS EXPERIMENTOS.....	83
8.1    Modelo general .....	83
8.2    Modelo individual.....	85
8.3    Comparativa de Resultados Modelo General-Modelo Individual .....	97

CAPÍTULO 9: CONCLUSIONES .....	99
9.1    Introducción.....	99
9.2    Conclusiones.....	99
9.3    Mejoras y líneas de investigación futuras.....	100
CAPÍTULO 10: BIBLIOGRAFÍA .....	102
PARTE II: PRESUPUESTO.....	106
PARTE III: PLIEGO DE CONDICIONES .....	114

## *Índice de figuras*

FIGURA 2. 1. CICLO HIDROLÓGICO [10] .....	10
FIGURA 2. 2. MAR DE NUBES DE LAS ISLAS CANARIAS.....	13
FIGURA 2. 3. EN LA IZQUIERDA, PLUVIÓMETRO CON EMBUDO PARA AUMENTAR EL ÁREA DE CAPTACIÓN DEL AGUA DE LA PRECIPITACIÓN. EN LA DERECHA, UBICACIÓN DEL PLUVIÓMETRO ESTABLECIDA POR LA NORMA EN ESPAÑA [14,15].....	14
FIGURA 2. 4. A LA IZQUIERDA, PLUVIÓMETROS VAISALA WXT530.....	15
FIGURA 2. 5. PARTES DE UN PLUVIÓGRAFO [16].....	15
FIGURA 2. 6. DISTINTOS EJEMPLOS DE PLUVIÓGRAFO ANALÓGICO [17].....	16
FIGURA 2. 7. PLUVIÓGRAFO DIGITAL [18].....	17
FIGURA 3. 1. UBICACIÓN CÁMARA HOSPITAL 1 – BARRANCO SECO.....	21
FIGURA 3. 2. UBICACIÓN CÁMARA HOSPITAL 2 - CATEDRAL .....	21
FIGURA 3. 3. UBICACIÓN CÁMARA HOSPITAL 3 - ISLETA.....	21
FIGURA 3. 4. UBICACIÓN CÁMARA HOSPITAL 4 - ESCALERITAS .....	21
FIGURA 3. 5. IMAGEN GRABADA POR HOSPITAL 1 – BARRANCO SECO .....	22
FIGURA 3. 6. IMAGEN GRABADA POR HOSPITAL 2 – CATEDRAL .....	22
FIGURA 3. 7. IMAGEN GRABADA POR HOSPITAL 3 - ISLETA .....	22
FIGURA 3. 8. IMAGEN GRABADA POR HOSPITAL 4 - ESCALERITAS.....	22
FIGURA 3. 9. UBICACIÓN CÁMARA TAFIRA 1 - INFORMÁTICA.....	22
FIGURA 3. 10. UBICACIÓN CÁMARA TAFIRA 2 – MONTAÑA ARUCAS .....	22
FIGURA 3. 11. IMAGEN GRABADA POR TAFIRA 1 - INFORMÁTICA .....	23
FIGURA 3. 12. IMAGEN GRABADA POR TAFIRA 2 – MONTAÑA ARUCAS .....	23
FIGURA 3. 13. UBICACIÓN CÁMARA TAFIRA 3 -FOSCAM .....	23
FIGURA 3. 14. UBICACIÓN CÁMARA TAFIRA 4 -FOSCAM .....	23
FIGURA 3. 15. IMAGEN GRABADA POR TAFIRA 3 - FOSCAM .....	23
FIGURA 3. 16. IMAGEN GRABADA POR TAFIRA 4 - FOSCAM .....	23
FIGURA 3. 17. ORGANIZACIÓN POR CÁMARA DE LA BASE DE DATOS. ....	24
FIGURA 3. 18. ORGANIZACIÓN DE LAS SECUENCIAS PARA CADA CÁMARA. ....	25
FIGURA 3. 19. ORGANIZACIÓN DE LOS VÍDEOS POR CADA SECUENCIA.....	25
FIGURA 4. 1. PREPROCESADO DE SECUENCIAS DE VÍDEOS. ....	29
FIGURA 4. 2. HERRAMIENTA DE NIVELES DE POTENCIA. ....	30
FIGURA 4. 3. ORGANIZACIÓN DE LOS DÍAS DE ALMACENAMIENTO DE LOS VÍDEOS DE MARZO.....	30
FIGURA 4. 4. ORGANIZACIÓN DE LOS VÍDEOS DE UN DÍA. ....	31
FIGURA 4. 5. ORGANIZACIÓN POR SECUENCIAS DE VÍDEO POR CÁMARA.....	31
FIGURA 4. 6. VÍDEOS DE UNA SECUENCIA ALMACENADA EN LA BASE DE DATOS .....	31
FIGURA 4. 7. MATRIZ DE 3X3 PARA LA ELECCIÓN DE LA ROI.....	32
FIGURA 4. 8. IMAGEN NORMAL – ROI nº4 DE LA CÁMARA HOSPITAL1- BARRANCOSECO.....	33

FIGURA 4. 9. ZOOM DE LOS PÍXELES QUE FORMA LA IMAGEN. ....	34
FIGURA 4. 10. GRADO DE OSCURIDAD DE UN PÍXEL. ....	34
FIGURA 4. 11. ROI N°4 – FILTRADO SOBEL DE EVENTO DE NO LLUVIA DE LA CÁMARA HOSPITAL1- BARRANCOSECO..	34
FIGURA 4. 12. ROI N°4 – FILTRADO SOBEL DE EVENTO DE LLUVIA DE LA CÁMARA HOSPITAL1- BARRANCOSECO. ....	35
FIGURA 5. 1. DESCRIPCIÓN DE UN PIXEL.....	39
FIGURA 5. 2. DESCOMPOSICIÓN DE LOS COLORES RGB.....	40
FIGURA 5. 3. CAPA KERNEL. ....	40
FIGURA 5. 4. FUNCIONAMIENTO FILTRO KERNEL. ....	41
FIGURA 5. 5. DESCRIPCIÓN DE PROCESO DE DETECCIÓN CARACTERÍSTICAS. ....	41
FIGURA 5. 6. ALGORITMO MAX-POOLING [17].....	42
FIGURA 5. 7. ALGORITMO AVERAGE-POOLING [17].....	42
FIGURA 5. 8. CAPAS TOTALMENTE CONECTADAS DE UNA RNN. ....	43
FIGURA 5. 9. ESTRUCTURA DE LA RED LSTM .....	45
FIGURA 5. 10. ESTRUCTURA DE LA PRIMERA PARTE DE UNA RED LSTM.....	46
FIGURA 5. 11. ESTRUCTURA DE LA SEGUNDA PARTE DE UNA RED LSTM.....	46
FIGURA 5. 12. ESTRUCTURA DE LA TERCERA PARTE DE UNA RED LSTM.....	46
FIGURA 6. 1.ESQUEMA GENERAL DEL MÉTODO DE DETECCIÓN Y CUANTIFICACIÓN.....	49
FIGURA 6. 2. IMAGEN DE LA CÁMARA HOSPITAL1-BARRANCOSECO. FOTOGRAMA DE TIPO NN. ....	50
FIGURA 6. 3. ROI N°4 DE LA CÁMARA HOSPITAL1- BARRANCOSECO. FOTOGRAMA DE TIPO NN.....	51
FIGURA 6. 4. APLICACIÓN DEL FILTRO SOBEL EN IMÁGENES NN. ....	52
FIGURA 6. 5. IMAGEN DE LA CÁMARA HOSPITAL1-BARRANCOSECO. FOTOGRAMA DE TIPO NB.....	52
FIGURA 6. 6. ROI N°4 DE LA CÁMARA HOSPITAL1- BARRANCOSECO. FOTOGRAMA DE TIPO NB. ....	53
FIGURA 6. 7. APLICACIÓN DEL FILTRO SOBEL EN IMÁGENES NB.....	53
FIGURA 6. 8. IMAGEN DE LA CÁMARA HOSPITAL1-BARRANCOSECO. FOTOGRAMA DE TIPO NA. ....	54
FIGURA 6. 9. ROI N°4 DE LA CÁMARA HOSPITAL1- BARRANCOSECO. FOTOGRAMA DE TIPO NA.....	54
FIGURA 6. 10. APLICACIÓN DEL FILTRO SOBEL EN IMÁGENES NA.....	55
FIGURA 6. 11. COMPARATIVA NN-NA.....	55
FIGURA 6. 12. COMPARATIVA NB-NA .....	56
FIGURA 6. 13. CAPAS DE LA RED LSTM .....	58
FIGURA 6. 14. OPCIONES DE ENTRENAMIENTO DE LA RED LSTM. ....	59
FIGURA 6. 15. EJEMPLO DE ENTRENAMIENTO DE UNA RED LSTM EN ESTE TFG.....	59
FIGURA 6. 16. PRUEBA GRÁFICA DE LA FUNCIÓN “CONFUSIONCHART “ DE MATLAB. ....	65
FIGURA 6. 17. RESULTADOS EN EXCEL DE LA CÁMARA HOSPITAL1-BARRANCOSECO. ....	65
FIGURA 7. 1. PRIMERA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	72
FIGURA 7. 2. SEGUNDA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	73
FIGURA 7. 3. TERCERA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	75
FIGURA 7. 4. PRIMERA PARTE DE EXPLICACIÓN DEL ALGORITMO “PROCESADO_IMAGEN_PRUEBA2”.....	76
FIGURA 7. 5 SEGUNDA PARTE DE EXPLICACIÓN DEL ALGORITMO “PROCESADO_IMAGEN_PRUEBA2”.....	77
FIGURA 7. 6. TERCERA PARTE DE EXPLICACIÓN DEL ALGORITMO “PROCESADO_IMAGEN_PRUEBA2”. ....	78
FIGURA 7. 7. CUARTA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	79
FIGURA 7. 8. QUINTA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	79
FIGURA 7. 9. SEXTA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN. ....	80
FIGURA 7. 10. SÉPTIMA PARTE DE EXPLICACIÓN DEL ALGORITMO DE DETECCIÓN Y CUANTIFICACIÓN.....	81
FIGURA 7. 11. RESULTADOS DEL EXPERIMENTO EN EXCEL. ....	81
FIGURA 8. 1. RESULTADOS EXCEL DEL ANÁLISIS DE FORMA CONJUNTA DE TODAS LAS CÁMARAS. ....	84
FIGURA 8. 2. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE TODAS LAS CÁMARAS. ....	85
FIGURA 8. 3. RESULTADOS EXCEL DEL ANÁLISIS DE LA CÁMARA HOSPITAL1-BARRANCOSECO. ....	86
FIGURA 8. 4. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA HOSPITAL1-BARRANCOSECO..	87
FIGURA 8. 5. RESULTADOS EXCEL DE LA CÁMARA HOSPITAL2-CATEDRAL. ....	88

FIGURA 8. 6. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA HOSPITAL2-CATEDRAL.....	88
FIGURA 8. 7. RESULTADOS EXCEL DE LA CÁMARA HOSPITAL3-ISLETA.....	89
FIGURA 8. 8. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA HOSPITAL3-ISLETA.....	89
FIGURA 8. 9. RESULTADOS EXCEL DE LA CÁMARA HOSPITAL4-ESCALERITAS.....	91
FIGURA 8. 10. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA HOSPITAL4-ESCALERITAS.....	91
FIGURA 8. 11. RESULTADOS EXCEL DE LA CÁMARA TAFIRA1-INFORMÁTICA.....	92
FIGURA 8. 12. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA TAFIRA1-INFORMÁTICA.....	92
FIGURA 8. 13. RESULTADOS EXCEL DE LA CÁMARA TAFIRA2-MONTAÑAARUCAS.....	93
FIGURA 8. 14. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA TAFIRA2-MONTAÑAARUCAS.....	94
FIGURA 8. 15. RESULTADOS EXCEL DE LA CÁMARA TAFIRA3-FOSCAM.....	95
FIGURA 8. 16. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA TAFIRA3-FOSCAM.....	95
FIGURA 8. 17. RESULTADOS EXCEL DE LA CÁMARA TAFIRA4-FOSCAM.....	96
FIGURA 8. 18. RESULTADOS EXCEL DE LA MEDIA Y DESVIACIÓN TÍPICA DE LA CÁMARA TAFIRA4-FOSCAM.....	96

## *Índice de tablas*

TABLA 2. 1. ESTRUCTURA DE LA LLUVIA.....	12
TABLA 6. 1. MATRIZ 3X3 DE UNA IMAGEN.....	51
TABLA 6. 2. MATRIZ DE CONFUSIÓN BINARIA PARA LA DETECCIÓN DE LA EVENTOS DE LLUVIA.....	61
TABLA 6. 3. MATRIZ DE CONFUSIÓN BINARIA CON LA INTERPRETACIÓN DE LOS RESULTADOS OBTENIDOS EN LA DETECCIÓN DE EVENTOS DE LLUVIA.....	61
TABLA 6. 4. FORMULACIÓN DE CADA UNO DE LOS PARÁMETROS DE CALIDAD.....	62
TABLA 6. 5. MATRIZ DE CONFUSIÓN 3X3 PARA LA DETECCIÓN DE EVENTOS DE LLUVIA.....	63
TABLA 6. 6. MATRIZ DE CONFUSIÓN 3X3 CON LA INTERPRETACIÓN DE LOS RESULTADOS OBTENIDOS EN LA DETECCIÓN DE EVENTOS DE LLUVIA.....	63
TABLA 6. 7. MATRIZ DE CONFUSIÓN PARA LA DETECCIÓN DE LA EVENTOS DE LLUVIA.....	64
TABLA 7. 1. CÁMARAS QUE SE EVALUARÁN EN EL EXPERIMENTO.....	74
TABLA P. 1. PRECIOS Y COSTES DE AMORTIZACIÓN DE RECURSOS HARDWARE.....	109
TABLA P. 2. PRECIOS Y COSTES DE AMORTIZACIÓN DEL MOBILIARIO.....	109
TABLA P. 3. PRECIOS Y COSTES DE AMORTIZACIÓN DE RECURSOS SOFTWARE.....	110
TABLA P. 4. COSTE TOTAL DE MATERIAL.....	110
TABLA P. 5. PRESUPUESTO CON EL TRABAJO REALIZADO Y EL MATERIAL UTILIZADO.....	111
TABLA P. 6. PRESUPUESTO FINAL DEL TRABAJO DE FIN DE GRADO.....	112
TABLA C. 1. CARACTERÍSTICAS TÉCNICAS DEL MODELO GXV364_FHD.....	116
TABLA C. 2. CARACTERÍSTICAS TÉCNICAS DEL MODELO FOSCAM FI9901EP.....	118
TABLA C. 3. CARACTERÍSTICAS DEL PLUVIÓMETRO MODELO VAISALA WXT530.....	119
TABLA C. 4. CARACTERÍSTICAS DEL PLUVIÓMETRO MODELO VAISALA RG13.....	119
TABLA C. 5. CARACTERÍSTICAS TÉCNICAS DEL ORDENADOR ASUS.....	120
TABLA C. 6. CARACTERÍSTICAS TÉCNICAS DEL ORDENADOR ACER.....	120



# **PARTE I: MEMORIA**



# CAPÍTULO 1: INTRODUCCIÓN

## *Introducción*

La meteorología según el diccionario de la Real Academia Española de la Lengua (RAE) es [1]: “Ciencia que estudia los fenómenos atmosféricos”. Partiendo de los orígenes de la palabra, el prefijo de origen griego (meteorología); formado por “meteoros” cuyo significado es “Fenómeno natural no permanente que se produce en la atmósfera, como el viento, la lluvia, el arco iris, los rayos” y del sufijo «logía» que indica “estudio, tratado o ciencia.”. Por otro lado, otro de los términos que se asocia a meteorología es el de la climatología la cual se define como “una rama de la Geografía que estudia los fenómenos climáticos ocurridos en el pasado, lo que ocurre en el presente y lo que puede ocurrir a futuro”. Por lo tanto, cabe destacar que cuando hablamos de meteorología, estamos contextualizando al estudio de los fenómenos atmosféricos.

Un sistema de observación meteorológica se encarga de la medición y determinación de todas las variables atmosféricas que en su conjunto representan las condiciones del estado de la atmósfera en un momento dado y en un determinado lugar, utilizando instrumental adecuado en el lugar adecuado y complementado por los sentidos del observador meteorológico (si es necesario). Es necesario conocer el estado de las variables atmosféricas para hacer diagnósticos en tiempo real, previsión del tiempo, alertas meteorológicas y estudios del clima. Algunas actividades también necesitan conocer el estado actual del tiempo o la previsión a futuro para su funcionamiento, como ser aeropuertos y actividades agropecuarias.

El propósito de este Trabajo de Fin de Grado (TFG) es utilizar sistemas de observación que ya están implementados como es el caso de cámaras de videovigilancia para el seguimiento de riesgos medioambientales. La idea básica es plantear un funcionamiento alternativo y complementario a los métodos tradicionales actuales de tal forma que se aporta nuevo valor a la red de vigilancia.

Abordaremos una serie de objetivos que recorren la cadena de procesado en un sistema basado en Aprendizaje Máquina y, por extensión Inteligencia Artificial, aplicadas a la detección de lluvia, y en la medida de lo posible cuantificación, con la ayuda del entorno Matlab, que proporciona algunas facilidades como el procesamiento de imágenes o técnicas de Machine Learning que nos servirá para llevar a cabo este proyecto.

## ***Objetivos del Trabajo de Fin de Grado***

Para lograr la ejecución final de este proyecto, establecemos cinco objetivos principales:

1. Estudio de las **características** necesarias de los **dispositivos de captación** de imágenes y de los distintos modos de almacenamiento y codificaciones que podemos realizar en imagen y vídeo.
2. Preparación de una **base de datos** con imágenes, en la cual se ha de realizar una correcta clasificación de las imágenes estudiadas.
3. Estudio de diversas técnicas de **extracción de características de las imágenes** para reducir impurezas o mejorar la percepción de diferentes eventos.
4. Estudio de **regiones de interés** (Region of Interest, RoI) más adecuadas dentro de la imagen. Estas RoI son zonas de la imagen donde los efectos de la lluvia son más relevantes.
5. Estudio de los **algoritmos de reconocimiento de imágenes** aplicados a la detección de eventos. En esta parte usaremos técnicas de Machine Learning como pueden ser redes neuronales, bien sean tipo backpropagation o profundas con técnicas de Deep Learning (p.e., Convolutional Neural Network).

## ***Competencias de la titulación abordadas en el Trabajo de Fin de Título***

A lo largo del progreso de este TFG, se han desarrollado numerosas competencias que establece el Proyecto Docente de la asignatura. A continuación, las que hemos considerado más relevantes, se presentan clasificadas en generales y específicas.

Entre las competencias básicas encontramos:

- a) CB2 – Que los estudiantes sepan aplicar sus conocimientos a su trabajo o vocación de una forma profesional y posean las competencias que suelen demostrarse por medio de la elaboración y defensa de argumentos y la resolución de problemas dentro de su área de estudio.
- b) CG4 – Capacidad para diseñar e implementar sistemas de adquisición y procesado de señales.

En cuanto a las específicas:

- a) CR1 – Capacidad para aprender de manera autónoma nuevos conocimientos y técnicas adecuados para la concepción, el desarrollo o la explotación de sistemas y servicios de telecomunicación.
- b) CR3 – Capacidad para utilizar herramientas informáticas de búsqueda de recursos bibliográficos o de información relacionada con las telecomunicaciones y la electrónica.
- c) CTFG – Ejercicio original a realizar individualmente y presentar y defender ante un tribunal universitario, consistente en un proyecto en el ámbito de las tecnologías específicas de la Ingeniería de Telecomunicación de naturaleza profesional y en el que se sintetizen e integren las competencias adquiridas en las enseñanzas.

### ***Antecedentes***

Es consustancial a los seres humanos manifestar interés por las condiciones climáticas y, por ende, en la meteorología. Además, esto tiene multitud de otros fines, como son el cuidado de los cultivos, el transporte aéreo como marítimo o por carretera, la protección de las personas ante desastres naturales, entre otros muchos casos. Si a esto añadimos el creciente interés en los efectos del cambio climático, podemos convenir que observar y predecir las condiciones meteorológicas es de importancia vital.

Mediante la incorporación de nuevas tecnologías, a lo largo de los años se han venido realizando mejores estimaciones y predicciones de los fenómenos meteorológicos y, en general, del clima. Actualmente, la red de observación de la Organización Meteorológica Mundial (OMM) desarrolla proyectos para mejorar los sistemas de observación actuales. En los últimos años, OMM ha incorporado nuevas tecnologías, tales como, estaciones meteorológicas, radares meteorológicos, satélites meteorológicos, boyas meteorológicas, los buques de observación marítima, las radiosondas, entre otros. En este TFG damos un paso más y evolucionamos hacia el uso de imágenes de cámaras de observación en exteriores [2,3].

En la actualidad, los sistemas de videovigilancia son más frecuentes en todo tipo de instalaciones y más populares como sistema de seguridad. Existen varias tecnologías que implementan este sistema entre las que se encuentran las analógicas, ip, hdcvi, entre otras. Además, su campo de utilización se extiende a cualquier sector con la finalidad de proteger a las personas, materiales, el tráfico, turismo, etc.

Desde el punto de vista de este Proyecto utilizamos cámaras en el campo de la meteorología para extender y, en la medida de lo posible, abaratar los costes que implican el uso de sistemas meteorológicos. Por otro lado, teniendo en cuenta que este tipo de cámaras se sitúan en lugares muy diversos, podemos obtener un gran despliegue de videocámaras en amplias zonas ya que muchos sistemas de videovigilancia pueden ser cedidos por organismos oficiales, empresas privadas o aficionados a la meteorología a través de la red. Además, tenemos la posibilidad de instalar cámaras si existiera un objetivo específico en una zona determinada.

Nuestro trabajo se integra en un sistema de vigilancia meteorológica para el seguimiento de riesgos medioambientales. La idea básica es plantear un funcionamiento alternativo y complementario a los métodos tradicionales actuales de tal forma que se aporta nuevo valor a la red de vigilancia. Las líneas de trabajo que se desarrollarán están integradas en el Proyecto con acrónimo VIMETRI-MAC, y este TFG es continuación del TFM actualmente en curso, y próximo a su finalización, realizado por Dña. Nayra D. Rosales Hernández. Este proyecto lleva por título "SISTEMA DE VIGILANCIA METEOROLÓGICA PARA EL SEGUIMIENTO DE RIESGOS MEDIOAMBIENTALES", código MAC/3.5b/065, que tiene la Universidad de las Palmas de Gran Canaria como Jefe de Filas, y la Universidad de Madeira y el Laboratório Regional de Engenharia Civil como Socios (ambos en Madeira). Además, tiene como participantes asociados la Dirección General de Telecomunicaciones y Nuevas Tecnologías (Gobierno de Canarias), Dirección General de Seguridad y Emergencias (Gobierno de Canarias), Agencia Estatal de Meteorología. Fue aprobado en la Primera convocatoria dentro del Programa de Cooperación Territorial. INTERREG V A España-Portugal. MAC 2014-2020.

Abordaremos una serie de objetivos que recorren la cadena de procesado en un sistema basado en Aprendizaje Máquina y, por extensión Inteligencia Artificial, aplicadas a la detección de lluvia, y su potencial cuantificación. Así estudiaremos el uso de preprocesado basado en definir la ROI y establecer el tamaño, etc. También, estudiaremos técnicas posteriores de procesado para hacer

transformaciones que permiten detectar variaciones (p.e., Sobel) [3,4] o extraer características con potencial discriminante [5,6], etc. Nos plantearemos incluso usar técnicas computacionales de fusión ya conocidas en el ámbito de la multimedia [7]. El Machine Learning que nos planteamos usar está basado en redes neuronales. Particularmente, dado su uso con éxito en numerosas aplicaciones, comenzaremos por técnicas de Deep Learning (p.e., Recurrent Neural Networks, Convolutional Neural Network) [8].

Además, debemos tener en cuenta que utilizaremos cámaras de videovigilancia, que aporta el Proyecto VIMETRI-MAC en varios puntos del municipio de Las Palmas de Gran Canaria tomando como objetivo la detección de eventos de lluvias.

### *Estructura de la memoria*

- **Capítulo 1. Introducción.** Capítulo dedicado a la presentación del proyecto en la que se comentan los contenidos, competencias y objetivos principales a alcanzar.
- **Capítulo 2. La precipitación.** En este capítulo se realizará un estudio sobre los diferentes ámbitos de la precipitación.
- **Capítulo 3. La base de datos.** En este capítulo detallamos la organización de la base de datos utilizada para la detección y la cuantificación de eventos de lluvia.
- **Capítulo 4. Procesado y extracción de características de la imagen.** En este capítulo estudiaremos la etapa de preprocesado previa por la que pasaremos las imágenes antes de ser entregadas a la red LSTM.
- **Capítulo 5. Marco metodológico para la clasificación de las imágenes.** En este capítulo se estudiará el campo de la monitorización meteorológica. Para ello, emplearemos el aprendizaje máquina para la detección y cuantificación de eventos de lluvia (o no) basándonos en secuencias de vídeos.

- **Capítulo 6. Método de detección y cuantificación de precipitación a partir de imágenes.** En este capítulo se expone el método que hemos utilizado para detectar y cuantificar el nivel de precipitación de lluvia a partir de secuencias de vídeos recibidas desde diferentes cámaras de videovigilancia.
- **Capítulo 7. Implementación del método de detección y cuantificación.** En este capítulo se expone el funcionamiento del algoritmo que hemos utilizado para la detección de eventos de lluvia a partir de secuencias de vídeos.
- **Capítulo 8. Resultados finales de los experimentos.** En este capítulo mostraremos los datos de los experimentos que hemos realizado.
- **Capítulo 9. Conclusiones.** En este apartado se presentan todas las conclusiones del proyecto que hemos desarrollado, así como las mejoras y líneas futuras.
- **Capítulo 10. Bibliografía.** En este último capítulo, presentamos todas las fuentes bibliográficas que nos han servido como referencia para realizar el proyecto.
- **Presupuesto.** Detallamos el coste de este proyecto.
- **Pliego de condiciones.** En este apartado describimos con detalle las características de los equipos que hemos utilizado en este TFG.



# CAPÍTULO 2: LA PRECIPITACIÓN

En este capítulo presentamos un estudio sobre la precipitación. Particularmente, abordamos su definición, formación, clasificación según su naturaleza física, mecanismos de formación, formación de meteoros y estructura, medidores actuales y análisis de las variables necesarias para la cuantificación de la lluvia.

## *2.1 Definición de precipitación*

Para definir correctamente la precipitación es necesario definir previamente meteoro e hidrometeoro, además de otros fenómenos asociados. La Organización Meteorológica Mundial (OMM) define el meteoro de la siguiente forma [9]:

“Un meteoro es un fenómeno observado en la atmósfera o sobre la superficie de la tierra, que consiste en una suspensión, una precipitación, o un depósito de partículas líquidas, acuosas o no, o de partículas sólidas, o un fenómeno de la naturaleza de manifestación óptica o eléctrica”.

Dependiendo de la naturaleza de las partículas que constituye los meteoros y de los procesos físicos que implica su ocurrencia, se pueden clasificar en cuatro grupos: hidrometeoros, litometeoros, fotometeoros y electrometeoros.

### **Hidrometeoro:**

“Un hidrometeoro es un meteoro que consiste en un conjunto de partículas de agua líquida o sólida, suspendidas en la atmósfera o cayendo a través de ella, o que son empujadas por el viento desde la superficie de la tierra, o depositadas sobre objetos que se encuentran sobre el suelo o en el aire libre.”. Por ejemplo: lluvia, nieve y granizo [9].

### **Litometeoro:**

“Un litometeoro es un meteoro que consiste en un conjunto de partículas, la mayoría de las cuales son sólidas y no acuosas. Las partículas están más o menos suspendidas en el aire, o son levantadas por el viento desde el suelo.”. Por ejemplo: la calima de polvo, tormenta de arena y el humo [9].

**Fotometeoros:**

“Un fotometeoro es un fenómeno luminoso producido por la reflexión, refracción, difracción o interferencia de luz proveniente del Sol o la Luna.”. Por ejemplo: arco iris, espejismos y rayos crepusculares [9].

**Electrometeoros:**

“Un electrometeoro es una manifestación visible o audible de la electricidad atmosférica. Los electrometeoros corresponden a descargas eléctricas discontinuas (relámpagos, truenos) o se producen como fenómenos más o menos continuos (fuego de San Telmo, aurora polar).”. Por ejemplo: relámpagos, truenos, fuego de San Telmo y aurora polar [9].

Por lo tanto, la precipitación consiste en la caída desde la atmósfera hasta la superficie de la tierra o evaporarse completamente mientras caen un conjunto de partículas denominadas anteriormente como hidrometeoros, ya sea en estado líquido, tales como la lluvia o llovizna, o en estado sólido tal como la nieve, cinarra, nieve granulada, polvo diamante, hielo granulado y granizo.

## ***2.2 Formación de la precipitación***

La formación de la precipitación sigue un ciclo denominado ciclo hidrológico o ciclo del agua. Este ciclo se basa en un proceso de circulación del agua entre las diferentes capas de la hidrosfera donde se minimiza las reacciones químicas, ya que sólo se efectúa el traslado del agua con la ayuda del cambio de su estado físico. Estos ciclos mantienen una cantidad de agua constante pero su distribución no es uniforme, va cambiando.

Los pasos que desarrolla el ciclo hidrológico son los siguientes:

- **Evaporización:** El agua presente en la superficie terrestre se evapora gracias al calor del sol del que toma su energía. Esto da lugar a un cambio del estado físico del agua, pasar de un estado líquido a uno sólido.

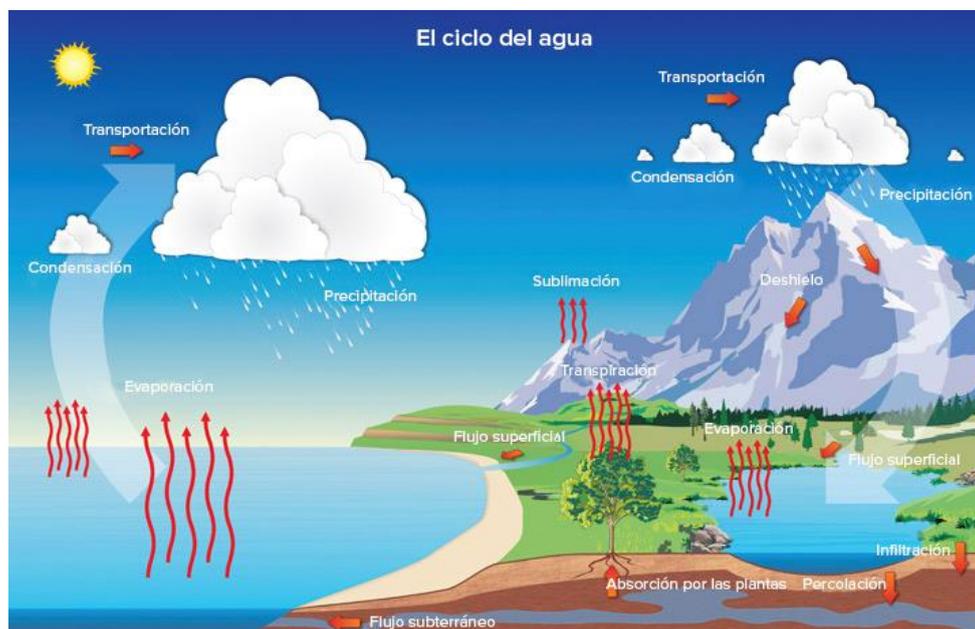


Figura 2. 1. Ciclo Hidrológico [10]

- **Condensación:** El vapor de agua va ascendiendo entre las diferentes capas de la hidrosfera, al ir ascendiendo se va enfriando y esto ocasiona que el agua se vaya condensando, es decir, cambia su estado físico de un estado de vapor a un estado líquido. Genera diversas moléculas de agua denominadas aerosoles de diferentes tamaños (entre 0.1 a 10 $\mu$ m de diámetro) que se unen formando núcleos de condensación. Esta unión da lugar a la formación de nubes, niebla y cristales de hielo.
- **Precipitación:** a medida que van ascendiendo los aerosoles van incrementando su tamaño por condensación hasta un punto en el que son lo suficientemente pesados como para precipitarse, esto ocurre cuando tienen un diámetro superior a 0.1mm. Parte de estas gotas en el descenso decrecen debido a la baja velocidad de su caída y vuelven a evaporizarse antes de alcanzar la superficie de la tierra y otras incrementan su tamaño debido al impacto y agregación y, además, poseen una velocidad mayor, es decir, superior a los 3 m/s, dando lugar a las gotas de lluvia.
- **Infiltración:** Las gotas de lluvia que llegan a la superficie de la tierra penetra el suelo y se une a aguas subterráneas.

- **Fusión:** Proceso a través del cual el agua en estado sólido que ha alcanzado las zonas altas de la superficie terrestre, tal como el granizo o la nieve, cambia de estado sólido a líquido, es decir, se produce el fenómeno del deshielo. De esta forma se encauza el agua por diferentes ríos hasta alcanzar el mar.
  
- **Escorrentía:** Debido a la fuerza de la gravedad las moléculas de agua se transportan desde las zonas altas de la superficie terrestre hasta los mares y océanos. Formando así los ríos y caudales subterráneos que originan el arrastre de sedimentos y provocan erosiones en la superficie terrestre. A partir de esta fase comienza el ciclo del agua nuevamente [11].

### ***2.3 Clasificación de la precipitación***

Existen diferentes formas de clasificar la precipitación, en este TFG nos centraremos en dos clasificaciones principales, estas son según:

- Su naturaleza física.
- Su estructura.

#### ***Clasificación según las características físicas***

Esta clasificación se centra en una descripción de los meteoros que forman la precipitación. Los cuales, pueden adquirir diferentes formas y tamaños dependiendo del proceso de condensación recibido. Los más comunes son los siguientes:

- **Lluvia:** precipitación de las gotas de agua en estado líquido que poseen entre 0.1 y 5 mm de diámetro. Según su intensidad y duración se puede distinguir cuatro grandes grupos:
  - **Llovizna:** el diámetro de las gotas de agua es inferior a 0.5mm. tienen poca intensidad y poca duración.
  - **Chubascos:** precipitación de gran intensidad y corta duración.
  - **Aguacero:** precipitación de gran intensidad y media duración.
  - **Trombas:** precipitación de gran intensidad y larga duración.
  
- **Nieve:** precipitación de las gotas de agua en estado sólido con formas geométricas particulares. Según su diámetro se puede distinguir cuatro grandes grupos:

- **Nieve:** precipitación en forma de cristales de hielo. Su forma es hexagonal. Su tamaño puede alcanzar centímetros de diámetro.
- **Escarcha:** gránulos de hielo de gotas de agua que se han congelado sobre objetos de la superficie terrestre.
- **Granizo:** precipitación en forma de bolas de hielo. Según su forma pueden ser esferoidales, cónicos o irregulares. Su tamaño está comprendido entre 5-125 mm de diámetro [12].

**Clasificación según la estructura**

La precipitación se puede clasificar según su estructura vertical u horizontal, para un mejor estudio de espacio alcanzado y el tiempo de duración de esta. La clasificación se puede observar en la siguiente tabla:

	Estructura de lluvia	
	Horizontal	Vertical
Región de distribución de la precipitación	Amplia	Reducida, pero se extiende desde la superficie terrestre hasta una altura de la isoterma de 0°C
Mecanismo de formación	Precipitación orográfica.	Precipitación convectiva y frontales.
Cantidad de precipitación	Ligera	Intensa
Homogeneidad	No homogénea	Si homogénea
Tipo de precipitación	Débil	Fuerte

Tabla 2. 1. Estructura de la lluvia

Las Islas Canarias están ubicadas en una región considerada subtropical. Las islas reciben los vientos alisios, un viento húmedo procedente del noreste. Debido a los vientos alisios al que están expuestas, se obtiene una capa superficial húmeda superpuesta a una capa seca, generando un cambio brusco de temperatura. Este cambio da lugar a nubes de tipo estratocúmulos, e impide el desarrollo de nubes de desarrollo vertical o nubes de grandes cúmulos. Este tipo de nube es conocida en Canarias como “el mar de nubes”. Esto ocasiona escasas precipitaciones.

Sin embargo, las islas cuentan con una gran variedad de vegetación: Unos de los más destacados “los bosques de laurisilva”. La captación del agua que obtiene esta vegetación se debe a las

precipitaciones de estructura de lluvia horizontal. Esto, da lugar a una presencia de forma continuada de nubes bajas que al encontrar obstáculos (zonas montañosas) obliga a estas nubes a ascender generando una elevación mecánica del aire. Este ascenso por el obstáculo provoca que el aire se enfríe y, debido a esto, el vapor de agua se condensa y se precipita sobre la vegetación o por el contacto de las nubes con la vegetación.

Un ejemplo son Las Breñas en La Palma, donde se registra entre 1000 y 1500 litros de agua al año [13].



Figura 2. 2. Mar de nubes de las Islas Canarias.

#### ***2.4 Medidores de la precipitación actuales***

Actualmente, para cuantificar las precipitaciones es necesario el uso de determinados dispositivos o sistemas, tales como, pluviómetros, pluviógrafos, redes pluviométricas y estaciones climatológicas. A continuación, se realizará una breve descripción de cada uno de estos dispositivos o sistemas de captación y cuantificación de la precipitación:

- **Pluviómetro:**

Un pluviómetro es un aparato que sirve para medir la cantidad de precipitación caída durante un cierto tiempo. La idea base de este dispositivo descansa en el hecho de que la lluvia se mide por la cantidad de milímetros que alcanzaría el agua en un suelo perfectamente horizontal, que no tuviera ningún tipo de filtración o pérdida. Se han ideado infinidad de artilugios para este cometido, pero con el fin de hacer las medidas uniformes, la OMM (Organización Meteorológica Mundial) recomienda una serie de normas destinadas a que las medidas, por una parte, tengan la adecuada precisión y por otra, sean capaces de evitar múltiples errores que harían inviables y

absurdas las medidas.

Un pluviómetro está formado por una serie de vasos cilíndricos en cuya boca de recepción lleva un aro de borde muy afilado y calibrado a  $200 \text{ cm}^2$ . Generalmente, se fabrican en chapa de metales diversos, cortando y plegando laminas cuyas superficies y aristas hay que dar forma, remachar, soldar, etc. Tanto es así que los contornos a unir mediante soldaduras suman más de 190 centímetros, lo que requiere una laboriosa y costosa mano de obra.

En cuanto a los vasos, deben ser lo suficientemente profundos para que las gotas que han entrado no salgan al rebotar en el fondo, por lo que éste deberá tener una adecuada inclinación, con dos misiones, evitar el efecto vertical de rebote y conducir rápidamente el agua caída a un recipiente de boca estrecha llamado vasija, que queda acoplada al terminal del embudo, con lo que todo el agua recogida se conserva en un recinto perfectamente aislado por cámaras de aire entre dobles paredes, ya que la precipitación ha de permanecer durante horas hasta su medida, generalmente por la mañana.

La medida de la precipitación se realiza vertiendo el agua recogida en una probeta graduada, calculada exactamente respecto a la superficie calibrada de recepción del pluviómetro, con lo que mide exactamente y de forma directa, milímetros y décimas de milímetro de lluvia o lo que es lo mismo litros y décimas de litro por metro cuadrado.

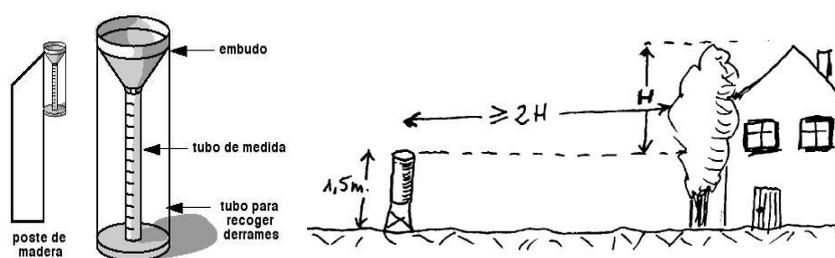


Figura 2. 3. En la izquierda, pluviómetro con embudo para aumentar el área de captación del agua de la precipitación. En la derecha, ubicación del pluviómetro establecida por la norma en España [14,15].

En las imágenes anteriores encontramos algunas aplicaciones de estos dispositivos y las normas que deben cumplir en cuanto a espacio y ubicación.

Los pluviómetros que usamos en este TFG son del tipo que podemos observar en la siguiente imagen:



Figura 2. 4. A la izquierda, pluviómetros VAISALA WXT530.  
A la derecha, VAISALA pluviómetro RG13.

Las características técnicas del pluviómetro VAISALA WXT530 y VAISALA RG13 están explicadas detalladamente en el pliego de condiciones que se adjunta al final de esta memoria.

▪ **Pluviógrafo:**

Es un instrumento meteorológico que registra de forma mecánica y continua la precipitación en una gráfica, que permite conocer la cantidad total, duración, intensidad y periodo en el que ha tenido lugar un evento de lluvia teniendo en cuenta las mismas consideraciones del suelo perfectamente horizontal e impermeable que utiliza un pluviómetro.

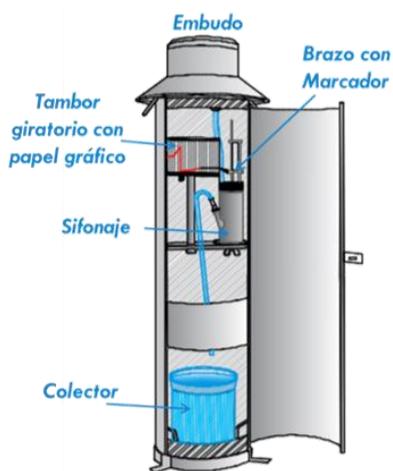


Figura 2. 5. Partes de un pluviógrafo [16].

**Funcionamiento:** Al igual que el pluviómetro, tiene un embudo en la parte superior por donde se recolecta la lluvia hasta un reservorio llamado sifonaje, en el cual se encuentra un flotador, que al recibir cierta cantidad de precipitación (10 mm) envía la lluvia hacia un colector en la parte inferior del instrumento.

Al pasar el agua al colector, el flotador vuelve a su punto inicial y por medio de un brazo con un marcador de punta fina con tinta que este tiene, permite esbozar las variaciones de la precipitación en un tambor con papel gráfico, esto se repite hasta que termina el periodo de precipitación de la lluvia. El registro del tambor se verifica y archiva diariamente [16].

Este dispositivo puede ser **analógico o digital**.

**Pluviógrafo analógico:** Existen gran variedad de pluviómetros analógicos, pero los más comunes son el medidor de flotador, el medidor de balanza y el medidor de cubeta basculante, como se ilustra en la figura 2.6.



Figura 2. 6. Distintos ejemplos de Pluviógrafo analógico [17].

Concretamente, el ejemplo que se encuentra a la derecha de la figura anterior, es el que se utiliza en el pabellon B del edificio de Telecomunicaciones.

**Pluviógrafo digital:** Pluviógrafos con sensores que registran de forma digital y automática los datos y los envían mediante conexión inalámbrica. Como se ilustra en la figura 2.7.



Figura 2. 7. Pluviógrafo digital [18].

#### ▪ **Redes pluviométricas:**

Son redes de pluviómetros y estaciones meteorológicas que se instalan para la investigación de la precipitación en zonas de estudio determinadas o de interés. Para un diseño correcto de una red se debe de tener en cuenta:

- El espacio entre estaciones meteorológicas, esto dependerá si el estudio es sobre tormentas genéricas (más espaciado) o el estudio de patrones de las tormentas (menos espaciado).
- Densidad de la red, esto dependerá si las precipitaciones son fuertes (mayor densidad) o débiles (menor densidad).
- Orografía, relieve, etc.

La OMM establece las recomendaciones para las densidades de las redes pluviométricas. En Canarias, al ser una región montañosa en zona tropical la recomendación es de 100 a 250Km<sup>2</sup> por estación [9].

#### ▪ **Estaciones climatológicas:**

Es un dispositivo cuyo objetivo es la medición y el posterior registro de diversos fenómenos meteorológicos, tales como el viento, la temperatura, la humedad, la insolación, la precipitación y la evaporización.

Todos los dispositivos usados exigen un nivel de normalización, ya que serán usados en diferentes estudios alrededor del mundo [19].

En este proyecto, abordamos la detección y la cuantificación mediante cámaras de videovigilancia en exteriores y algoritmos de aprendizaje máquina (Machine Learning o Deep

Learning, en su acepción en lengua inglesa), en apartados posteriores de esta memoria profundizaremos sobre esto. En este apartado nos centraremos en una parte fundamental del aprendizaje, esta es, la captación de información de referencia. Partimos de la base de que para realizar el aprendizaje usaremos una estrategia donde se necesitan datos de referencia veraces que integrar en el proceso. Es lo que se llama aprendizaje supervisado. A tal efecto, haremos uso de dos pluviómetros propios, mediciones de radioenlaces y los datos de AEMET. Con estos datos verificaremos si los resultados obtenidos son correctos.



# CAPÍTULO 3: LA BASE DE DATOS

En este capítulo vamos a explicar cómo se ha creado y organizado la base de datos utilizada para la detección de secuencias temporales de vídeos donde se manifiestan (o no) precipitaciones de lluvia. Por lo tanto, describiremos la forma de captar dichas secuencias y su almacenamiento. Tal como ya hemos adelantado, estas imágenes pertenecen a la red de videocámaras del proyecto VIMETRI-MAC, que están desplegadas en diferentes puntos de la isla de Gran Canaria.

Este se basa en la idea de hacer entrenamiento supervisado, esto es, disponemos de las imágenes y cada una lleva un etiquetado manual que indica a qué clase pertenece (p.e., lluvia, no lluvia). El capítulo se divide en dos secciones:

## **Captación de los datos**

- Fuentes de los datos recogidos.
- Ilustración de la ubicación y situación de las cámaras.
- Captura de imagen de visión de cada cámara

## **Organización de las imágenes**

- Descripción detallada e ilustración de la organización de las carpetas utilizadas en la base de datos.
- Descripción e ilustración de la nomenclatura de los nombres de los vídeos.
- Descripción de la cantidad de vídeos seleccionados para la base de datos con eventos de lluvia y sin lluvia.

### ***3.1 Captación de los datos***

Para realizar el análisis de eventos de lluvia y no lluvia, tenemos que captar diferentes secuencias de diferentes momentos del día y noche. Este proceso de captación lo vamos a realizar a través de cámaras instaladas en exteriores, de las cuales vamos a explicar diferentes aspectos.

**Ubicaciones o bases de los equipos instalados:**

- Base Hospital Rey Juan Carlos I.
- Base ULPGC. Edificio de Electrónica y Telecomunicación, en la cubierta del pabellón B.

A continuación, en las siguientes figuras se muestran las cámaras ubicadas en la base Hospital Rey Juan Carlos I:



Figura 3. 1. Ubicación cámara Hospital 1 – Barranco Seco



Figura 3. 2. Ubicación cámara Hospital 2 - Catedral



Figura 3. 3. Ubicación cámara Hospital 3 - Isleta



Figura 3. 4. Ubicación cámara Hospital 4 - Escaleritas

En las siguientes figuras se observan las capturas de imagen de visión de cada cámara:



Figura 3. 5. Imagen grabada por Hospital 1 – Barranco Seco



Figura 3. 6. Imagen grabada por Hospital 2 – Catedral



Figura 3. 7. Imagen grabada por Hospital 3 - Isleta



Figura 3. 8. Imagen grabada por Hospital 4 - Escaleritas

En las siguientes figuras se muestran las cámaras ubicadas en la base ULPGC, en el Edificio de Electrónica y Telecomunicación, en la cubierta del pabellón B:

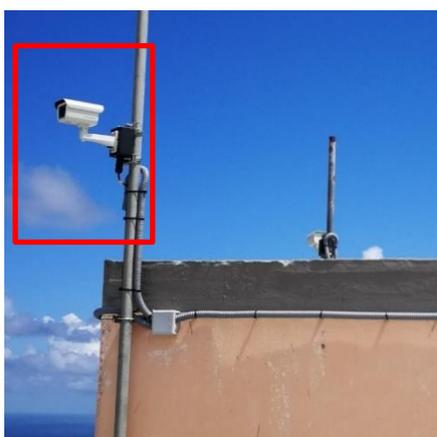


Figura 3. 9. Ubicación cámara Tafira 1 - Informática



Figura 3. 10. Ubicación cámara Tafira 2 – Montaña Arucas

En las imágenes 3.11 y 3.12 se observa la captura de imagen de visión de cada cámara:



Figura 3. 11. Imagen grabada por Tafira 1 - Informática



Figura 3. 12 Imagen grabada por Tafira 2 – Montaña Arucas

Las cámaras FOSCAM utilizadas en este TFT se muestran ubicadas en la base ULPGC, en el Edificio de Electrónica y Telecomunicación, en la cubierta del pabellón B:



Figura 3. 13. Ubicación cámara Tafira 3 - FOSCAM



Figura 3. 14. Ubicación cámara Tafira 4 - FOSCAM

En la figura 3.15 y 3.16 se observa la captura de imagen de visión de cada cámara:

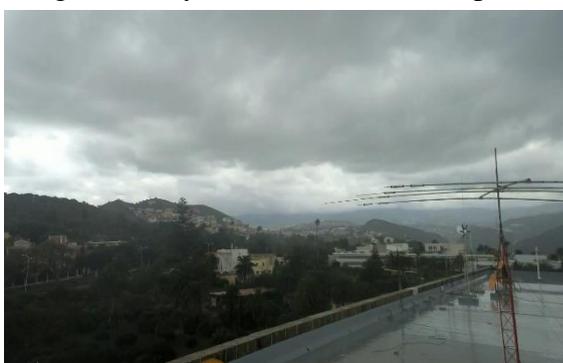


Figura 3. 15. Imagen grabada por Tafira 3 - FOSCAM



Figura 3. 16. Imagen grabada por Tafira 4 - FOSCAM

### 3.2 Organización de los datos

La base de datos se llama “Videovigilancia\_Secuencial” y está formada por las siguientes carpetas:

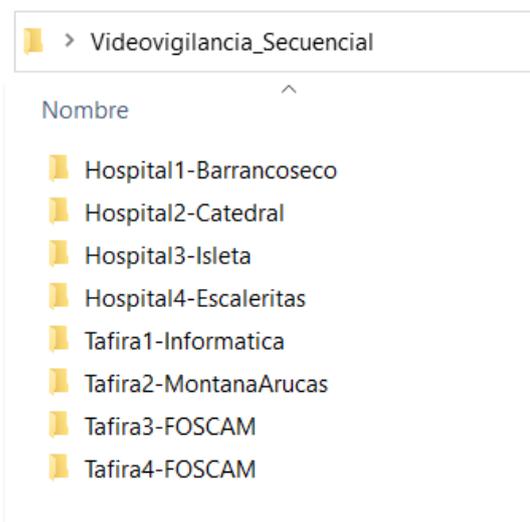


Figura 3. 17. Organización por cámara de la base de datos.

Como se ilustra en la imagen anterior, está formada a su vez por 8 carpetas. Cada una de estas carpetas contienen los datos recogidos por cada una cámara de las que disponemos para el estudio de este proyecto:

#### **Base Hospital Rey Juan Carlos I:**

- Hospital 1 – Barranco Seco
- Hospital 2 – Catedral
- Hospital 3 – Isleta
- Hospital 4 – Escaleritas

#### **Base ULPGC. Edificio de Electrónica y Telecomunicación, en la cubierta del pabellón B:**

- Tafira 1 – Informática
- Tafira 2 – Montaña Arucas
- Tafira 3 – FOSCAM
- Tafira 4 – FOSCAM

A su vez, como se observa en la Figura 3.18, cada una de estas carpetas se divide en secuencias, cuyo contenido pertenece a vídeos que se registran en una misma franja horaria que incluye eventos de lluvia teniendo en cuenta momentos anteriores y posteriores a dichos eventos en lo que no existe lluvia:

Nombre	Fecha de modificación	Tipo
sec01	17/11/2020 12:48	Carpeta de archivos
sec02	17/11/2020 12:55	Carpeta de archivos
sec03	17/11/2020 13:04	Carpeta de archivos
sec04	17/11/2020 13:15	Carpeta de archivos
sec05	17/11/2020 13:23	Carpeta de archivos
sec06	17/11/2020 13:22	Carpeta de archivos
sec07	17/11/2020 13:26	Carpeta de archivos
sec08	17/11/2020 13:29	Carpeta de archivos
sec09	17/11/2020 13:31	Carpeta de archivos

Figura 3. 18. Organización de las secuencias para cada cámara.

Los vídeos se graban permanentemente, cada 5 minutos se toma un vídeo de 2 segundos pues es suficiente para recoger imágenes que muestren el estado meteorológico del momento. En el interior de cada una de las carpetas, nos encontramos aproximadamente 10 vídeos de 2 segundos de duración cada uno en las que se percibe una transición entre eventos sin lluvia y eventos con lluvias en una franja horaria determinada, cuya clasificación la podemos observar en la figura 3.19, en la etiqueta de cada vídeo. El criterio que hemos elegido para seleccionar cada uno de los vídeos que componen la secuencia es el de a partir de vídeos donde se aprecia lluvia, escoger eventos de no lluvia anteriores a dichos vídeos y posteriores, de esta forma recogemos secuencias temporales de vídeos que reflejen los estados de lluvia que se dan en la realidad.

Nombre	Fecha	Tipo	Tamaño	Duración
2020032300441584924247Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.709 KB	00:00:02
2020032300461584924367Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.705 KB	00:00:02
2020032300481584924487Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.705 KB	00:00:02
2020032300541584924847Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	1.640 KB	00:00:02
2020032300561584924967Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	1.426 KB	00:00:02
2020032300581584925087Tafira2-MontanaAruacas_SL_NB	15/07/2020 10:41	AVI Video File (VLC)	1.461 KB	00:00:02
2020032301041584925447Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.693 KB	00:00:02
2020032301061584925567Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.682 KB	00:00:02
2020032304301584937806Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	1.867 KB	00:00:02
2020032304321584937927Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	1.661 KB	00:00:02
2020032304341584938047Tafira2-MontanaAruacas_SL_NB	15/07/2020 10:41	AVI Video File (VLC)	1.786 KB	00:00:02
2020032306341584945247Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	2.019 KB	00:00:02
2020032306361584945367Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.841 KB	00:00:02
2020032306381584945486Tafira2-MontanaAruacas_SL_NA	15/07/2020 10:41	AVI Video File (VLC)	1.904 KB	00:00:02
2020032306401584945607Tafira2-MontanaAruacas_NN	15/07/2020 10:41	AVI Video File (VLC)	1.829 KB	00:00:02

Figura 3. 19. Organización de los vídeos por cada secuencia.

En cuanto a la nomenclatura de los vídeos nos fijaremos en los siguientes parámetros:

**AAAAMMDD hhmmss \_NC**

**AAAAMMDD:** Este parámetro nos proporciona información sobre la fecha del vídeo captado, su año, mes y día.

**hhmmss:** Este parámetro nos proporciona información sobre la hora del vídeo captado en horas, minutos y segundos.

**NC:** Este parámetro proporciona información sobre los niveles de clasificación que hemos establecido por cada secuencia, los cuales están directamente relacionado con la clasificación según las características físicas de la lluvia que establecimos en el capítulo anterior:

- **NN:** No hay eventos de lluvia.
- **NB:** Si hay un evento de lluvia de nivel bajo, lo asociamos a eventos como llovizna.
- **NA:** Si hay un evento de lluvia de nivel alto, lo asociamos a eventos como chubascos, aguacero o tromba.

Esta base de datos contiene aproximadamente:

- Numero de vídeos de eventos con nivel bajo de lluvia: 200
- Número de vídeos de eventos con nivel alto de lluvia: 200
- Número de vídeos de eventos sin ningún evento de lluvia: 400



## CAPÍTULO 4: PREPROCESADO Y EXTRACCIÓN DE CARACTERÍSTICAS DE LA IMAGEN.

En este capítulo se describirán los ajustes y tareas de preprocesado de las imágenes a tratar, y, posteriormente, se le aplicará un filtro de gradiente para realzar, previamente, dichas imágenes al aprendizaje máquina.



Figura 4. 1. Preprocesado de secuencias de vídeos.

### 4.1 Captura de vídeos

El proyecto VIMETRI recoge en una base de datos vídeos de 2 segundos cada 2 minutos por cámara, los cuales se almacenan en carpetas organizadas por día. Para proceder a encontrar eventos de lluvia, al tener numerosos vídeos por día, utilizamos una herramienta que nos proporciona el mismo proyecto VIMETRI para saber en el día que estamos analizando si ha llovido o no, ya que registra los niveles de potencia de un receptor satelital, observando los picos que se pueden generar los cuales nos indica hay un evento de lluvia. Además, nos dan una aproximación muy precisa (da una muestra cada 15 segundos) de la hora a la que ha sucedido dicho evento.



Figura 4. 2. Herramienta de niveles de potencia.

Por ejemplo, en este caso podemos apreciar como a las 18:00 aproximadamente durante un tiempo relativamente corto, existe un pico que nos ayuda a saber que en ese momento ha habido un evento de lluvia.

En base a ello, nosotros vamos a una carpeta cuya etiqueta será la fecha del día que contiene todos los vídeos que se han registrado.

20200306	15/07/2020 12:39	Carpeta de archivos
20200311	15/07/2020 12:40	Carpeta de archivos
20200312	15/07/2020 12:40	Carpeta de archivos
20200313	15/07/2020 12:40	Carpeta de archivos
20200314	15/07/2020 12:41	Carpeta de archivos
20200315	15/07/2020 12:42	Carpeta de archivos
20200316	15/07/2020 12:42	Carpeta de archivos
20200319	15/07/2020 12:42	Carpeta de archivos
20200321	15/07/2020 12:42	Carpeta de archivos
20200323	15/07/2020 12:42	Carpeta de archivos
20200326	15/07/2020 12:42	Carpeta de archivos
20200328	15/07/2020 12:42	Carpeta de archivos

Figura 4. 3. Organización de los días de almacenamiento de los vídeos de marzo.

Intentamos descartar los días que no tienen ningún pico y vamos directamente a la carpeta que puede contener algún evento de lluvia. El registro de carpetas que vemos en la imagen anterior se corresponde al mes de marzo, el cual los dos últimos dígitos de la etiqueta corresponden al día, los dos dígitos que le siguen se corresponden al mes y los últimos cuatro empezando por la derecha corresponden al año.

Una vez entramos en la carpeta vamos a ir directamente a la hora que creemos que pueda existir el evento de lluvia.

2020030617521583517125Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	739 KB	00:00:02
2020030617541583517245Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	745 KB	00:00:02
2020030617561583517365Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	709 KB	00:00:02
2020030617581583517485Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	667 KB	00:00:02
2020030618001583517605Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	717 KB	00:00:02
2020030618021583517725Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	882 KB	00:00:02
2020030618041583517844Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	847 KB	00:00:02
2020030618061583517965Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	975 KB	00:00:02
2020030618081583518085Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	1.481 KB	00:00:03
2020030618101583518205Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	1.261 KB	00:00:02
2020030618121583518325Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	1.323 KB	00:00:02
2020030618141583518445Tafira1-Informatica	15/07/2020 10:13	AVI Video File (VLC)	1.082 KB	00:00:02

Figura 4. 4. Organización de los vídeos de un día.

Nosotros sabemos la hora de cada uno de los vídeos, gracias a la etiqueta que tiene el vídeo, el cual se registra justamente a la hora que ocurre. Como podemos observar en la imagen justo después de los datos de día, mes y año, observamos la hora exacta de recogida de ese vídeo. Si vemos el que tenemos seleccionado en la imagen, apreciamos la hora 17:54:15 que se corresponderían a las horas, minutos y segundos.

Una vez visualizamos la secuencia, al final de cada vídeo añadimos la etiqueta nosotros consideramos en función de los eventos que hemos mencionado anteriormente, y los introducimos en la carpeta de cada una de las cámaras, de la forma siguiente:

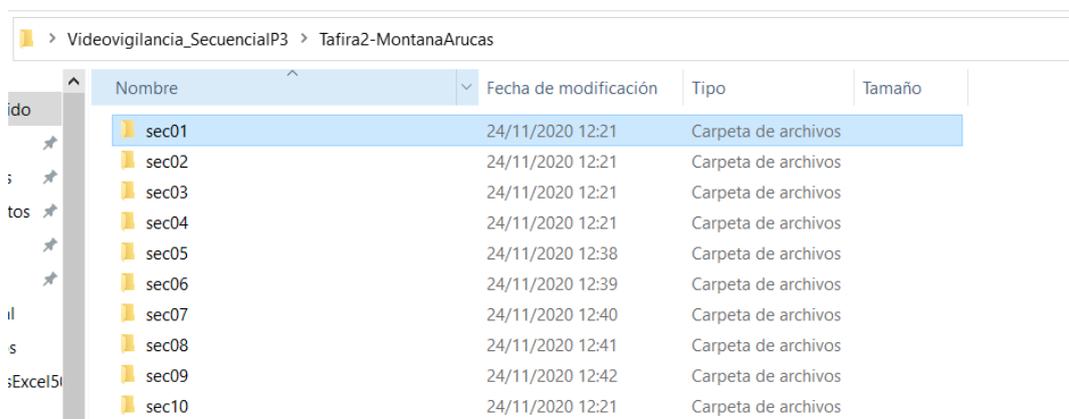


Figura 4. 5. Organización por secuencias de vídeo por cámara.

Como vemos en la Figura 4.5, en cada una de las cámaras creamos alrededor de 10 secuencias, realizando la clasificación final de las imágenes.

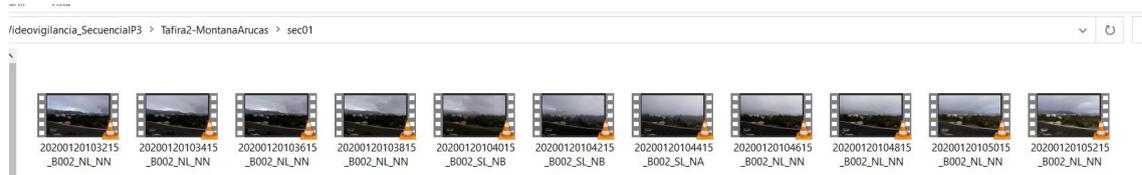


Figura 4. 6. Vídeos de una secuencia almacenada en la base de datos

La Figura 4.6 es una selección de imágenes que hemos clasificado como eventos de no lluvia (NN), lluvia de nivel bajo (NB) y de nivel alto (NA) en la cámara Tafira2-MontañaArucas. Están puestas en el orden temporal en que realmente se produjeron.

## 4.2 Descomposición de imágenes

Una vez tenemos las secuencias de vídeos correctamente clasificadas, tenemos que descomponer los vídeos en imágenes. Para ello, vamos accediendo a cada uno de los directorios de las cámaras para almacenar un número de frames (por ejemplo, 10, 20, etc.) por cada vídeo de cada secuencia que va a analizar la red neuronal, ya que consideramos un número suficiente para realizar los experimentos con éxito. No obstante, debemos tener en cuenta que podríamos recoger como máximo 60 frames ya que cada vídeo se compone de 2 segundos de duración.

## 4.3 Región de interés

Para disminuir el tamaño de la imagen y favorecer la eficiencia computacional del código hemos aplicado una técnica que nos permite segmentar la imagen en una matriz de 3x3, es decir, en nuevos cuadros. Esta técnica se basa en trabajar sobre una región de interés (Region of interest, ROI), la cual será diferente en función de cada cámara. Otro objetivo de las ROI es poder elegir las zonas de las cámaras que son más sensibles a reflejar la lluvia. También nos puede interesar para focalizar sobre una zona determinada de la zona geográfica de cobertura.

Para establecer una mejor explicación de esta técnica, tenemos la siguiente imagen:

<b>1</b>	<b>2</b>	<b>3</b>
<b>4</b>	<b>5</b>	<b>6</b>
<b>7</b>	<b>8</b>	<b>9</b>

Figura 4. 7. Matriz de 3x3 para la elección de la ROI.

Con esta división de la imagen, podemos seleccionar realizando un análisis previo de donde apreciamos mejor, eventos de lluvia dentro de una secuencia, el segmento que consideramos mejor para la detección de eventos de lluvia en cada cámara.

Además, debemos tener en cuenta que esta región es la que utilizaremos para que la red LSTM realice las labores de detección y cuantificación de lluvia.



Figura 4. 8. Imagen normal – ROI n°4 de la cámara Hospital1- Barrancoseco

Como podemos comprobar en este ejemplo, hemos escogido la ROI número 4 como Región de interés para la cámara Hospital1- Barranco seco.

Una vez hemos obtenido la imagen reducida solo con la ROI que consideramos mejor para cada cámara, necesitamos realizar un reajuste de la imagen, ya que todas la ROI en los que dividimos la imagen normal no miden lo mismo y, por lo tanto, aunque sea mínimo tienen tamaños diferentes. Esta diferencia se debe a que hay dos tipos de cámaras. Este reajuste lo realizamos porque el correcto funcionamiento de la red depende ello, ya que si detecta imágenes de diferentes tamaños no nos generará ningún resultado, provocando un error. Esto lo resolvemos estableciendo un tamaño de 200 de alto y 400 de ancho para cualquier ROI, medidas desde el punto central hacia sus extremos. Además, trabajar sobre la ROI nos proporcionará una disminución de tamaño en comparación con la imagen normal que hará que nuestro algoritmo pueda generar resultados con mayor rapidez, ya que funciona de forma más eficiente.

#### ***4.4 Algoritmo Sobel***

Este algoritmo calcula un operador que indica el gradiente de la intensidad de una imagen en cada pixel, esto facilita la detección de cambios dentro de una imagen con respecto a otra. Por lo tanto, se trata de un descriptor de características. Con este descriptor buscamos cambio asociados a la lluvia (por ejemplo, la presencia de gotas o trazas de ellas al caer y quedan en la imagen).

Los pasos que realiza este filtrado son los siguientes [4, 20, 21, 22]:

1. Se observan los píxeles de la imagen. Para cada píxel, queremos ver los píxeles que lo rodean.



Figura 4. 9. Zoom de los píxeles que forma la imagen.

2. A partir de la observación de los píxeles que le rodean al pixel que se está evaluando, determinamos el grado de oscuridad que existe entre ellos presentando posteriormente una flecha con la dirección en la que se vuelve más oscura. Las flechas las definimos como gradientes y nos presenta el cambio de flujo de claro a oscuro en la imagen.



Figura 4. 10. Grado de oscuridad de un píxel.

3. La imagen original se convierte en una representación de histogramas de gradientes orientados que captura las principales características de la imagen independientemente de los brillos de la imagen.

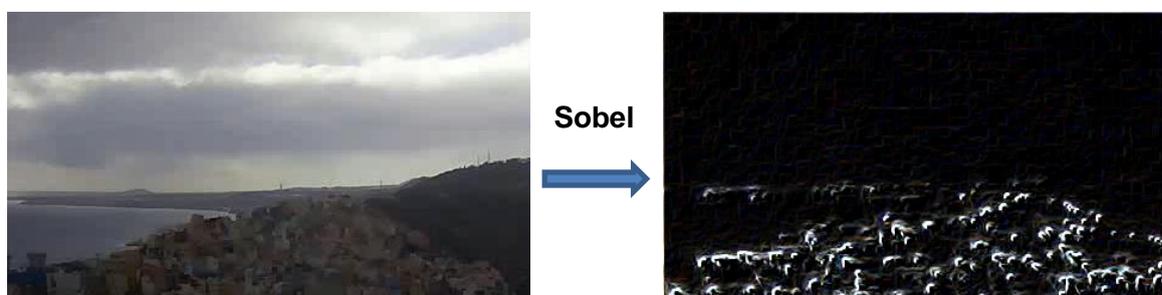


Figura 4. 11. ROI n°4 – Filtrado Sobel de evento de no lluvia de la cámara Hospital1-Barrancoseco.

En este caso hemos escogido un evento de no lluvia (NN) en el cual podemos observar que el filtrado que realizamos permite resaltar los bordes de la imagen.



Figura 4. 12. ROI n°4 – Filtrado Sobel de evento de lluvia de la cámara Hospital1-Barrancoseco.

Por otro lado, aquí tenemos un ejemplo del análisis que se realiza de eventos de lluvia a nivel alto (NA) donde podemos ver que los bordes de la imagen se diluyen y no se aprecian de forma muy precisa.



# CAPÍTULO 5: MARCO METODOLÓGICO PARA LA CLASIFICACIÓN DE LAS IMÁGENES

En la actualidad, el aprendizaje máquina juega un papel muy importante en múltiples áreas de la ciencia, industria e incluso de las finanzas. Este tipo de aprendizaje ayuda a resolver con mayor eficacia y rapidez problemas complejos. Veamos algunos ámbitos de aplicación.

En el área **médica** se utiliza para diversos campos:

- **Identificador de factores de riesgos:** Identificar si un paciente es probable que esté desarrollando un cáncer.
- **Predictivo:** Predecir si un paciente puede tener un ataque al corazón.
- **Estimador:** Estimar las cantidades de azúcar en sangre de un paciente diabético.

En el área **financiera**:

- **Predictivo:** Predecir el precio de una acción financiera basándose en el estudio de la empresa y su plan estratégico.

En el área **industrial**:

- **Estimador:** Estimar las existencias de una empresa en los próximos meses para organizar un mejor control del inventario y anticiparse a futuros problemas.

En este TFG nos introducimos en el campo de la monitorización meteorológica, y hemos empleado el aprendizaje máquina para detectar y cuantificar la precipitación de la lluvia basándonos en secuencias de vídeo que recogemos desde cámaras de vigilancia desplegadas por el municipio de las Palmas de Gran Canaria.

## ***5.1 Redes neuronales convolucionales***

### ***Definición***

Las Redes neuronales convolucionales son un tipo de redes neuronales artificiales donde las “neuronas” corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico. Este tipo de red es una variación de un perceptrón multicapa, sin embargo, debido a que su aplicación es realizada en matrices bidimensionales, son muy efectivas para tareas de visión artificial, como en la clasificación y segmentación de imágenes, entre otras aplicaciones.

### ***Semejanzas con el cerebro humano***

El trabajo realizado por Hubel y Wiesel en 1959 jugó un papel importante en la comprensión sobre cómo funciona la corteza visual, particularmente las células responsables de la selectividad de orientación y detección de bordes en los estímulos visuales dentro de la corteza visual primaria. Dos tipos de células se identificaron debido a que tenían campos receptivos alargados, con lo cual tienen una mejor respuesta a los estímulos visuales alargados como las líneas y los bordes. Estas se denominan células simples y células complejas.

Las células simples tienen regiones excitadoras e inhibitorias, ambas forman patrones elementales alargados en una dirección, posición y tamaño en particular en cada célula. Si un estímulo visual llega a la célula con la misma orientación y posición, de tal manera que ésta se alinea perfectamente con los patrones creados por las regiones excitadoras y al mismo tiempo se evita activar las regiones inhibitorias, la célula es activada y emite una señal.

Las células complejas operan de una manera similar. Como las células simples, éstas tienen una orientación particular sobre la cual son sensibles. Sin embargo, éstas no tienen sensibilidad a la posición. Por ello, un estímulo visual necesita llegar únicamente en la orientación correcta para que esta célula sea activada.

### ***Cómo están construidas y cómo funcionan***

Las redes neuronales convolucionales consisten en múltiples capas de filtros convolucionales de

una o más dimensiones. Después de cada capa, por lo general se añade una función para realizar un mapeo causal no-lineal.

Como cualquier red empleada para clasificación, al principio estas redes tienen una fase de extracción de características, compuesta de neuronas convolucionales, luego hay una reducción por muestreo y al final tendremos neuronas de perceptrón más sencillas para realizar la clasificación final sobre las características extraídas.

La fase de extracción de características se asemeja al proceso estimulante en las células de la corteza visual. Esta fase se compone de capas alternas de neuronas convolucionales y neuronas de reducción de muestreo. Según progresan los datos a lo largo de esta fase, se disminuye su dimensionalidad, siendo las neuronas en capas lejanas mucho menos sensibles a perturbaciones en los datos de entrada, al mismo tiempo son activadas por características cada vez más complejas [23].

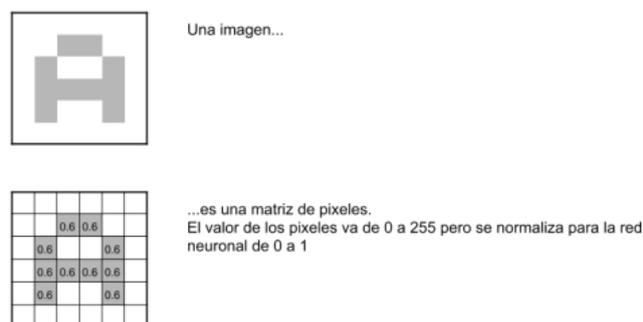


Figura 5. 1. Descripción de un píxel.

### ***Píxeles y neuronas***

Para comenzar, la red toma como entrada los píxeles de una imagen. Si tenemos una imagen con apenas 28x28 píxeles de alto y ancho, esto equivale a utilizar 784 neuronas. Y eso es si sólo tenemos 1 color (escala de grises). Si tuviéramos una imagen a color, necesitaríamos 3 canales RGB (red, green, blue) y entonces usaríamos  $28 \times 28 \times 3 = 2352$  neuronas. Estas neuronas constituyen nuestra capa de entrada.

### ***Preprocesamiento***

Antes de alimentar la red, hay que recordar que como entrada nos conviene convertir los valores

entre 0 y 1, y por tanto tendremos que dividirlos todos entre 255. Este 255 es porque los colores de los pixeles tienen valores que van del 0 al 255.

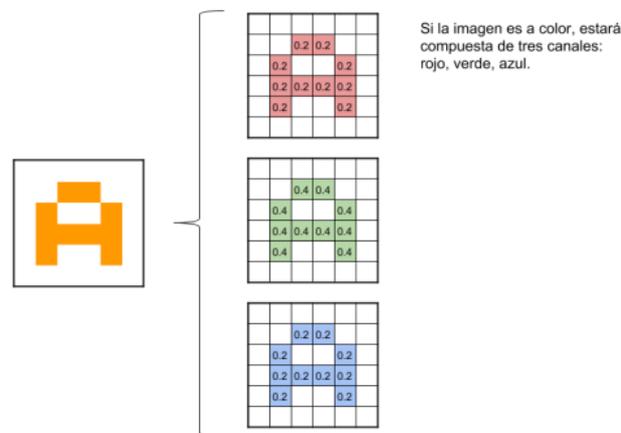


Figura 5. 2. Descomposición de los colores RGB.

### Convoluciones

Ahora comienza el “procesado distintivo” de las redes neuronales convolucionales, es decir, haremos las llamadas convoluciones: Estas consisten en tomar grupos de pixeles cercanos de la imagen de entrada e ir operando matemáticamente (producto escalar) contra una pequeña matriz que se llama Kernel. Ese Kernel supongamos que tiene un tamaño de 3×3 pixeles y con ese tamaño logra visualizar todas las neuronas de entrada (de izquierda-derecha, de arriba-abajo) y así logra generar una nueva matriz de salida, que en definitiva será nuestra nueva capa de neuronas ocultas.

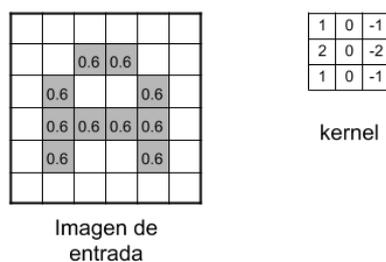


Figura 5. 3. Capa Kernel.

El kernel tomará inicialmente valores aleatorios y se irán ajustando mediante backpropagation. Una mejora es hacer que siga una distribución normal siguiendo simetrías, pero sus valores son aleatorios.

No aplicaremos 1 sólo kernel, si no que tendremos muchos kernel (al conjunto de Kernels se les

llama filtros).

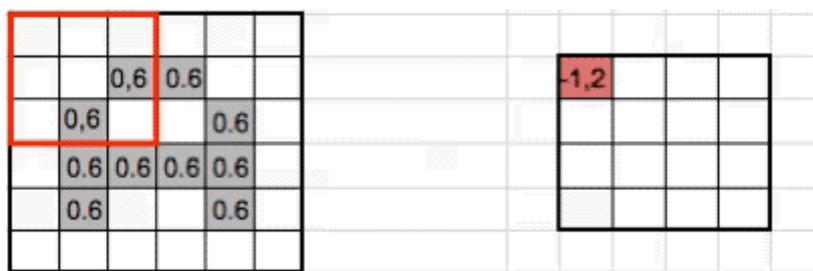


Figura 5. 4. Funcionamiento filtro Kernel.

Aquí vemos al kernel realizando el producto matricial con la imagen de entrada y desplazando de un en 1 en 1, el pixel de izquierda a derecha y de arriba-abajo y va generando una nueva matriz que compone al mapa de características.

En esta primera convolución y siguiendo con el ejemplo anterior, es como si obtuviéramos 32 imágenes filtradas nuevas. Estas imágenes nuevas lo que están “dibujando” son ciertas características de la imagen original. Esto ayudará en el futuro a poder distinguir un objeto de otro (por ej. Lluvia o no lluvia).

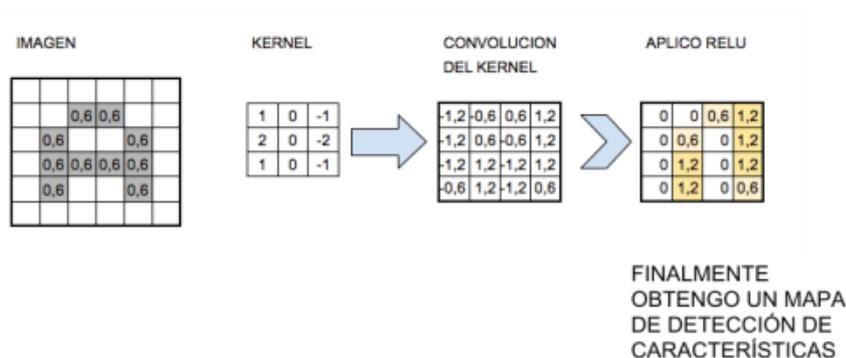


Figura 5. 5. Descripción de proceso de detección características.

### *Etapa de muestreo*

**Capa Max-Pooling o Average-Pooling:** Es la capa que realiza la reducción de los datos, es decir, reduce el ancho y el alto de las imágenes obtenidas de la capa convolucional, pero la profundidad la mantiene tal cual la recibió de la capa convolucional. Se basa en disminuir la cantidad de datos que presentan características comunes, para ello, realiza dos posibles tareas:

**Max-Pooling:** Calcula el máximo valor de una región determinada

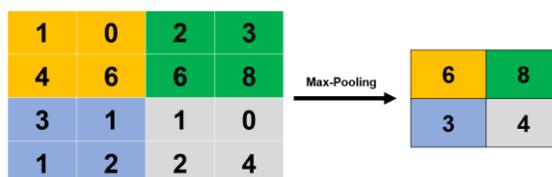


Figura 5. 6. Algoritmo Max-Pooling [17].

**Average-Pooling:** Calcula el promedio de una región determinada.

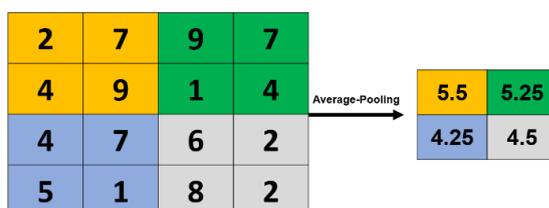


Figura 5. 7. Algoritmo Average-Pooling [17].

### *Etapa final*

**Capa clasificadora:** Capa que clasifica los datos obtenidos de la capa intermedia u oculta mediante clases predeterminadas.

**Capa de salida:** Capa formada por neuronas encargadas de recibir los datos de la capa clasificadora para posteriormente tomar una decisión y ofrecer un resultado de salida [24].

## **5.2 Redes neuronales recurrentes**

Las redes neuronales recurrentes están completamente conectadas, y tienen caminos de retroalimentación entre todos los elementos que las conforman. Una sola neurona está conectada a las neuronas posteriores en la siguiente capa, las neuronas pasadas de la capa anterior y a ella misma a través de vectores de pesos variables que sufren alteraciones en cada epoch o etapa en él, con el fin de alcanzar los parámetros o metas de operación.

La complejidad de este tipo de redes es alta en comparación con otros modelos, ya que realizan el intercambio de información entre neuronas en función de sus características, dependiendo del tipo de algoritmo de entrenamiento que se elija, pueden propagar la información hacia delante en el tiempo, lo cual equivale a predecir eventos. Esta es una característica muy importante para ciertas aplicaciones, como los ataques a la red, ya que la capacidad de predicción de eventos significativos basadas en las entradas anteriores al sistema le proporciona un beneficio importante a la seguridad de este [25].

Una característica importante en comparación con las CNNs convencionales es la inclusión de delays ( $Z^{-1}$ ) a la salida de las neuronas en las capas intermedias; las salidas parciales  $S_{mn}(t+1)$  se convierten en valores  $S_{mn}$ , un instante de tiempo anterior, y así se retroalimentan a todos los componentes de la red, guardando información de instantes de tiempo anteriores. Puede observarse cómo todos los nodos están interconectados entre sí y también con los nodos anteriores a ellos a través de conexiones directas y también delays antes de capa, o memorias temporales. El diagrama ha sido para no incurrir en excesiva complejidad, pero cada una de las capas está representada por cierto número de neuronas [25].

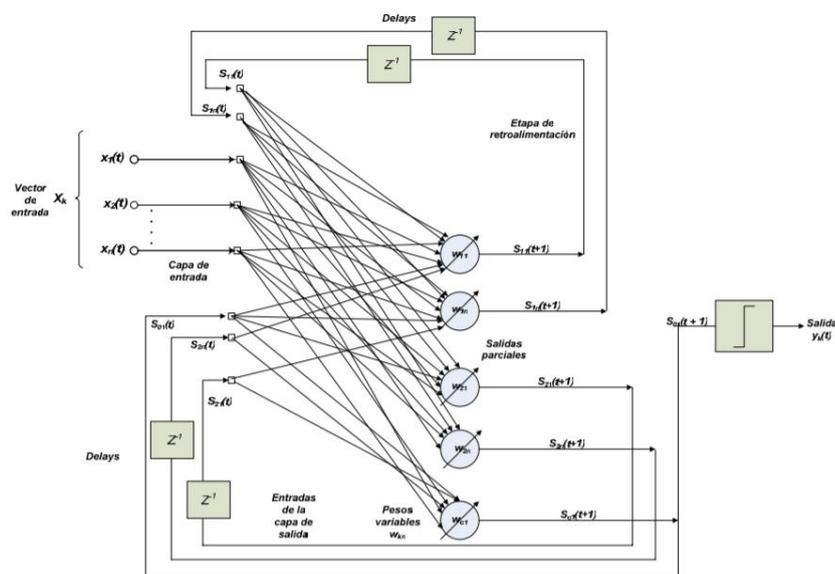


Figura 5. 8. Capas totalmente conectadas de una RNN.

### **5.3 Redes LSTM**

LSTM es un tipo único de red neuronal recurrente (RNN) capaz de aprender dependencias a largo plazo, lo que es útil para ciertos tipos de predicción que requieren que la red retenga información durante períodos de tiempo más largos, una tarea con la que luchan las RNN tradicionales.

#### ***El problema de las redes neuronales recurrentes***

Una red neuronal recurrente es un algoritmo de aprendizaje profundo diseñado para hacer frente a una variedad de tareas computacionales complejas, como la clasificación de objetos y la detección de voz. Los RNN están diseñados para manejar una secuencia de eventos que ocurren en sucesión, con la comprensión de cada evento basada en información de eventos anteriores.

Idealmente, preferiríamos tener los RNN más profundos para que pudieran tener un período de memoria más largo y mejores capacidades. Estos podrían aplicarse para muchos casos de uso del mundo real, como la predicción de valores y la detección mejorada de voz. Sin embargo, aunque suenan prometedores, los RNN rara vez se utilizan para escenarios del mundo real debido al problema del gradiente de desaparición.

#### ***El problema de gradiente que desaparece***

Este es uno de los desafíos más importantes para el desempeño de los RNN. En la práctica, la arquitectura de los RNN restringe sus capacidades de memoria a largo plazo, que se limitan a recordar solo unas pocas secuencias a la vez. En consecuencia, la memoria de los RNN solo es útil para secuencias más cortas y períodos de tiempo cortos.

El problema del gradiente de desaparición restringe las capacidades de memoria de los RNN tradicionales: agregar demasiados pasos de tiempo aumenta la posibilidad de enfrentar un problema de gradiente y perder información cuando usa la propagación hacia atrás [26].

Las redes LSTM están diseñadas para superar el problema del gradiente de desaparición y permitirles retener información durante períodos más largos en comparación con los RNN

tradicionales. Estas redes pueden mantener un error constante, lo que les permite continuar aprendiendo en numerosos pasos de tiempo y propagarse hacia atrás a través del tiempo y las capas.

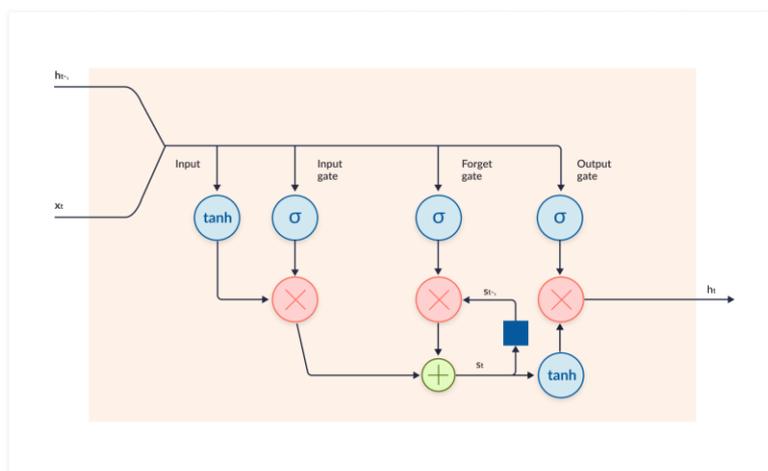


Figura 5. 9. Estructura de la red LSTM

Además, como se ve en el diagrama anterior, usan celdas cerradas para almacenar información fuera del flujo regular de la RNN. Con estas celdas, la red puede manipular la información de muchas formas, incluido el almacenamiento de información en las celdas y la lectura de ellas. Las células son capaces individualmente de tomar decisiones con respecto a la información y pueden ejecutar estas decisiones abriendo o cerrando las puertas.

La capacidad de retener información durante un largo período de tiempo le da a LSTM la ventaja sobre los RNN tradicionales en estas tareas.

### ***Arquitectura de memoria a corto plazo***

La arquitectura en forma de cadena de LSTM le permite contener información durante períodos de tiempo más largos, resolviendo tareas desafiantes con las que los RNN tradicionales luchan o simplemente no pueden resolver.

Las tres partes principales del LSTM incluyen:

**Olvidar puerta:** elimina la información que ya no es necesaria para completar la tarea. Este paso es fundamental para optimizar el rendimiento de la red.

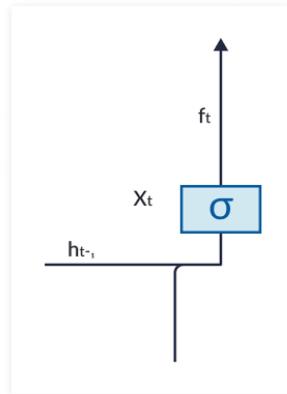


Figura 5. 10. Estructura de la primera parte de una red LSTM.

**Puerta de entrada:** responsable de agregar información a las celdas.

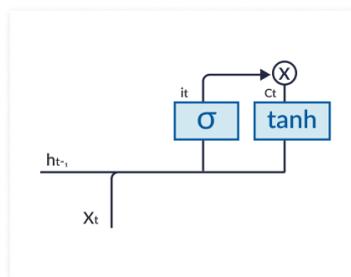


Figura 5. 11. Estructura de la segunda parte de una red LSTM.

**Puerta de salida:** selecciona y genera la información necesaria.

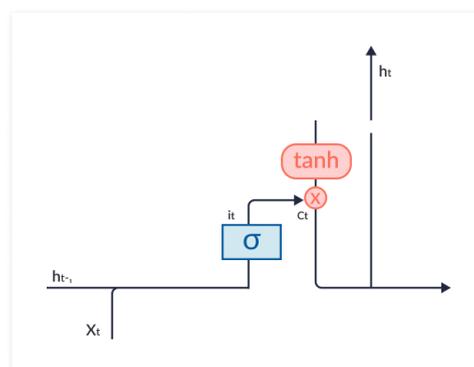


Figura 5. 12. Estructura de la tercera parte de una red LSTM.

### *Aplicaciones de las redes de memoria a corto plazo*

Estas redes se pueden aplicar a una variedad de tareas de aprendizaje profundo que incluyen principalmente predicciones basadas en información previa. Dos ejemplos dignos de mención incluyen la predicción de texto y la predicción de valores:

### ***Predicción de texto***

Las capacidades de memoria a largo plazo significan que sobresale en la predicción de secuencias de texto. Para predecir la siguiente palabra en una oración, la red debe retener todas las palabras que la precedieron. Una de las aplicaciones más comunes de predicción de texto son los chatbots utilizados por los sitios de comercio electrónico.

### ***Predicción de acciones***

Los modelos de aprendizaje automático simple (SML) pueden predecir los valores y precios de las acciones en función de datos como el valor de apertura y el volumen de las acciones. Si bien estos valores participan en la predicción de existencias, carecen de un componente clave. Para predecir correctamente el valor de una acción con alta precisión, el modelo debe tener en cuenta uno de los factores más importantes: la tendencia de la acción. Para hacerlo, el modelo debe identificar la tendencia en función de los valores registrados durante los días anteriores, una tarea adecuada para una red LSTM [26].



# CAPÍTULO 6: MÉTODO DE DETECCIÓN Y CUANTIFICACIÓN DE PRECIPITACIÓN A PARTIR DE SECUENCIAS DE VÍDEOS

En los capítulos anteriores hemos explicado el preprocesado de la señal recibida (capítulo 4) y el marco metodológico (capítulo 5). En este capítulo se expone el método que hemos utilizado para detectar y cuantificar el nivel de precipitación de lluvia a partir de vídeos recibidos desde diferentes cámaras de videovigilancia. Particularmente, para los experimentos utilizamos cámaras ubicadas en varios puntos de la isla de Gran Canaria.

## 6.1 Esquema general

En la figura 6.1 se muestra el esquema general del método de detección y cuantificación. El esquema consta de tres bloques fundamentales: Preprocesado, Red LSTM y Evaluación de resultados. Grosso modo, la finalidad de cada bloque es como sigue.

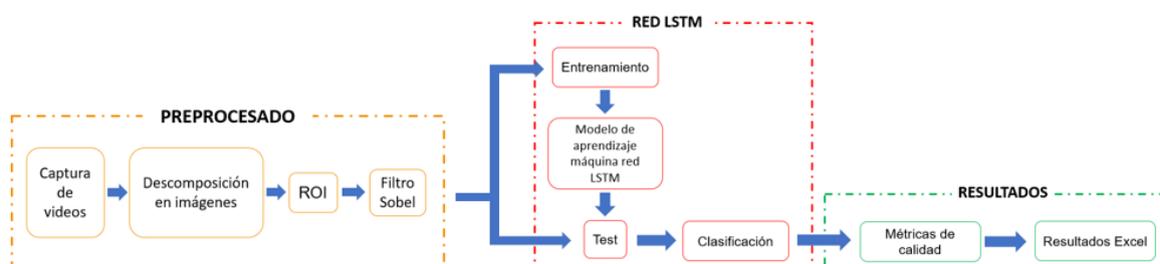


Figura 6. 1. Esquema general del método de detección y cuantificación.

- **Preprocesado:** En él se realizan la transformación de secuencias de vídeos a imágenes, la elección de la ROI para cada cámara, el establecimiento de un tamaño determinado de cada ROI y un filtrado de Sobel. Este bloque es común y representa en sí la fuente de datos que alimenta la red neuronal, tanto para entrenar como para clasificar.
- **Red LSTM:** En este bloque se hace el entrenamiento de la red y, una vez que se tiene el modelo correspondiente, se evalúa el mismo sobre los vídeos de test.

- **Evaluación de resultados:** Una vez la red termina de testear las secuencias, obtenemos las métricas de calidad con la exactitud, sensibilidad, especificidad y precisión, los cuales finalmente exportaremos a un archivo Excel para poder tener un conocimiento tangible del experimento que hemos realizado.

## 6.2 Preprocesado

En este apartado, vamos a definir cada uno de los tipos de imágenes que hemos clasificado con su preprocesado. Posteriormente daremos en una breve descripción la comparativa entre eventos de lluvia y no lluvia y, por otro lado, entre eventos de lluvia a nivel bajo y a nivel alto.

### *Eventos de no lluvia*

En este primer caso, vamos a estudiar el preprocesado que realizamos a las imágenes que hemos clasificado como NN, donde no se aprecian eventos de lluvia en ninguno de los segmentos de la imagen. Es, por ejemplo, el caso mostrado en la Figura 6.2 donde se muestra una imagen sin lluvia captado con la cámara Hospital1-Barrancoseco.



Figura 6. 2. Imagen de la cámara Hospital1-Barrancoseco. Fotograma de tipo NN.

Una vez tenemos esta imagen, para esta cámara hemos escogido la ROI nº4, pues es una de las que mejor permite apreciar cualquier tipo de evento que ocurra, y además permite detectar entradas de frentes lluviosos. Tenemos que recordar que dividimos la imagen en una matriz de 3x3:

<b>1</b>	<b>2</b>	<b>3</b>
<b>4</b>	<b>5</b>	<b>6</b>
<b>7</b>	<b>8</b>	<b>9</b>

Tabla 6. 1. Matriz 3x3 de una imagen.

La elección de la ROI, para cada una de las cámaras es la siguiente:

- Hospital1-Barrancoseco → ROI n°4.
- Hospital2-Catedral → ROI n°9.
- Hospital3-Isleta → ROI n°5.
- Hospital4-Escaleritas → ROI n°5.
- Tafira1-Informática → ROI n°5.
- Tafira2-MontañaArucas → ROI n°5.
- Tafira3-FOSCAM → ROI n°4.
- Tafira4-FOSCAM → ROI n°8.

En la siguiente figura tenemos el resultado de extraer la ROI correspondiente:



Figura 6. 3. ROI n°4 de la cámara Hospital1- Barrancoseco.  
Fotograma de tipo NN.

Una vez comprobamos que la región segmentada se ha obtenido correctamente, fijamos un valor de 200 de alto por 400 de ancho, para evitar problemas a la hora de que los segmentos que sacamos de cada imagen no sean del mismo tamaño.

Por último, realizamos el filtrado Sobel a la imagen ya segmentada.

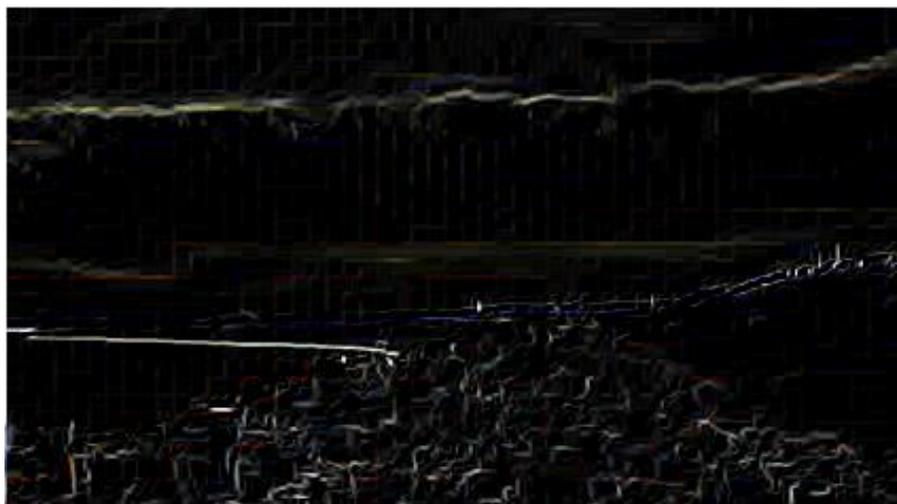


Figura 6. 4. Aplicación del filtro Sobel en imágenes NN.

### *Eventos de lluvia a nivel bajo*

En este segundo caso, vamos a estudiar el preprocesado que realizamos a las imágenes que hemos clasificado como NB, donde se aprecian eventos de lluvia de carácter moderado.

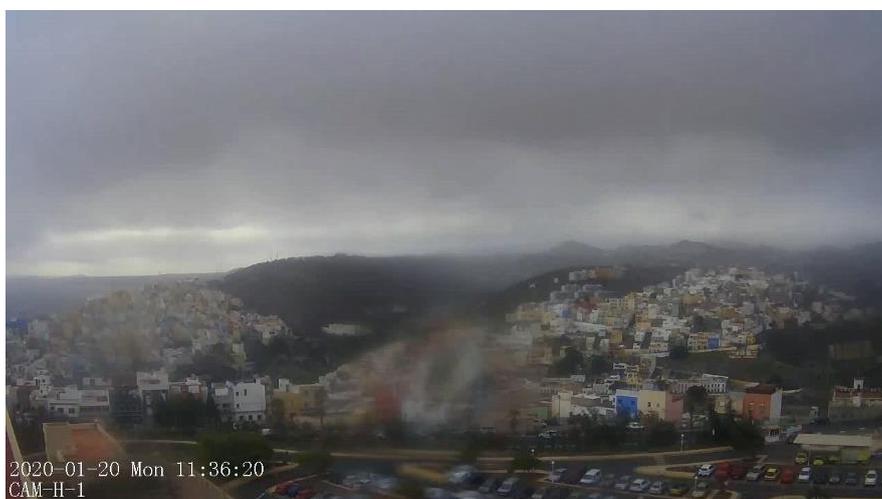


Figura 6. 5. Imagen de la cámara Hospital1-Barrancoseco.  
Fotograma de tipo NB.

Tomando la figura 6.5 como referencia, debemos tener en cuenta que en la ROI nº 7, podemos apreciar la hora y fecha superpuestas en la imagen, por lo que nunca la vamos a escoger para ninguna cámara debido a que darían lugar a fenómenos que no son reales y que podría

malinterpretar nuestra red. En todo caso, de ser necesario, se debería tomar una porción donde fecha y hora no aparezcan. Esto no ha sido necesario para este TFG.

Como resultado obtenemos esta imagen segmentada:



Figura 6. 6. ROI n°4 de la cámara Hospital1- Barrancoseco.  
Fotograma de tipo NB.

Por último, realizamos el filtrado Sobel a la imagen ya segmentada donde podemos apreciar con mayor detalle la diferencia entre eventos de no lluvia y eventos de lluvia.

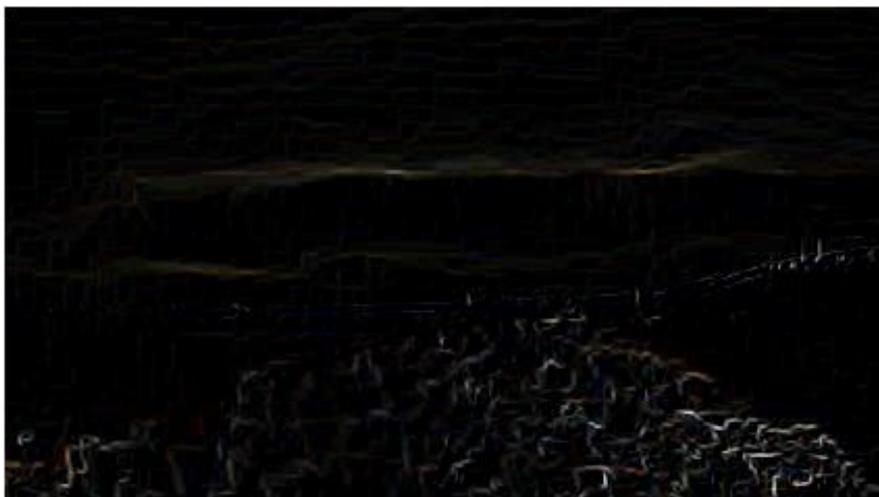


Figura 6. 7. Aplicación del filtro Sobel en imágenes NB.

***Eventos de lluvia a nivel alto***

En este tercer caso, vamos a estudiar el preprocesado que realizamos a las imágenes que hemos clasificado como NA, donde se aprecian eventos de lluvia de carácter alto.



Figura 6. 8. Imagen de la cámara Hospital1-Barrancoseco. Fotograma de tipo NA.

Como resultado obtenemos esta imagen segmentada:



Figura 6. 9. ROI n°4 de la cámara Hospital1- Barrancoseco.  
Fotograma de tipo NA.

Por último, realizamos el filtrado Sobel a la imagen ya segmentada.



Figura 6. 10. Aplicación del filtro Sobel en imágenes NA.

### *Análisis comparativo entre eventos de no lluvia y eventos de lluvia*

En este apartado veremos que el preprocesado que hacemos sobre las imágenes nos permite abordar un problema de clasificación para detectar y cuantificar eventos de lluvia a partir de imágenes y, de estas, aplicarlo en un contexto donde tenemos secuencias de vídeos. Con la ayuda de las imágenes recogidas en el apartado anterior vamos a realizar una comparación entre NN y NA, para ello vamos a recoger las mismas imágenes del filtrado de Sobel que se recogen para cada uno de los casos, ya que es la imagen final que evaluará la red:

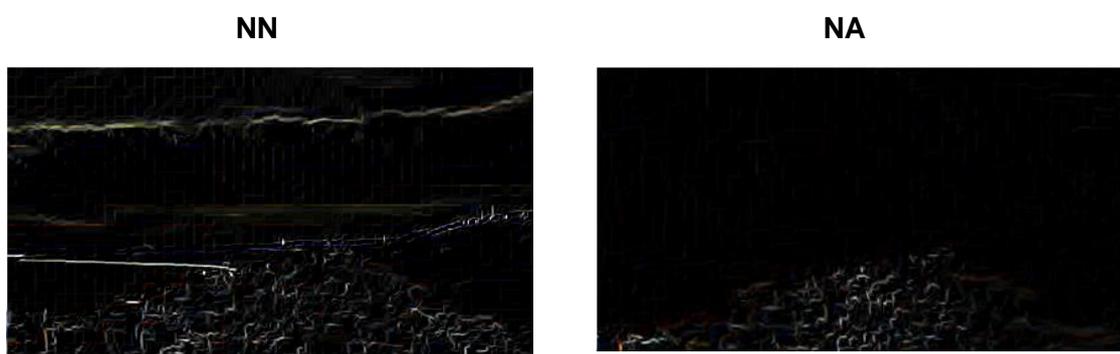


Figura 6. 11. Comparativa NN-NA.

Como podemos apreciar, la diferencia entre ambas imágenes es evidente, ya que en el caso de NN se recoge los contornos de la imagen original de una forma mucho más precisa mientras que en el caso NA, se difumina todos esos contornos que apreciábamos en NN, justamente en la parte

donde está la cámara enfocando a las nubes lo que nos da una idea de que existe lluvia en este caso. Podemos observar que el cielo se vuelve mucho más homogéneo lo que hace que el filtro no pueda detectar esos bordes dejando una parte de la imagen totalmente negra. Con esta descripción, podemos establecer que la problemática de detección de eventos de lluvias se puede abordar utilizando un filtro como este.

### ***Análisis comparativo entre eventos de lluvia a nivel bajo y eventos de lluvia de nivel alto***

En este apartado, con la ayuda de las imágenes recogidas en el apartado anterior vamos a realizar una comparación entre NB y NA, para ello vamos a ir recoger las mismas imágenes del filtrado de Sobel que se recogen para cada uno de los casos, ya que es la imagen final que evaluará la red:



Figura 6. 12. Comparativa NB-NA

La diferencia entre ambos casos es relativamente pequeña, pero debemos tener en cuenta que el filtro puede también diferenciar entre ambas imágenes debido a que el número de contornos o bordes son diferentes entre cada una de ellas, lo que a partir del entrenamiento que realiza la red puede obtener resultados de distinción realmente buenos.

### ***6.3 La Red LSTM***

En este apartado, tomando como referencia el capítulo 5 donde hablamos del funcionamiento de la red LSTM que utilizamos, vamos a describir las diferentes opciones que hemos seleccionado para su correcto funcionamiento.

En primer lugar, debemos tener en cuenta que cada imagen que preprocesamos antes de entrar en la red, la hemos convertido en un vector que recoge todos los píxeles de la imagen, ya que, de esta forma, es como la red LSTM elegida funciona.

En segundo lugar, vamos a hablar de las **capas** que utilizamos, las cuales se componen de 6 niveles:

- **1ª capa:** Es la capa de entrada, la cual se denomina “sequenceInputLayer”, donde se introducen los píxeles de la imagen en forma de vector.
- **2ª capa:** Es la capa LSTM, la cual se denomina “lstmLayer”. Esta capa procesará la salida de neuronas que están conectadas en “regiones locales” de entrada (es decir píxeles cercanos), calculando el producto escalar entre sus pesos (valor de píxel) y una pequeña región a la que están conectados en el volumen de entrada. En nuestro caso, utilizaremos 20 filtros y ese será el volumen de salida [23]. Por otro lado, al ser la capa LSTM, será la encargada también de recordar las características de todos los análisis para realizar una correcta evaluación [26].
- **3ª capa:** Es la capa en la que se almacena el resultado del análisis realizado por la capa anterior. Se denomina “dropoutLayer”.
- **4ª capa:** Es la que diferencia a otras redes (p.e., CNN) de una red LSTM, la cual se denomina “fullyConnectedLayer”, ya que necesitan muchas menos conexiones necesarias, pues realmente los pesos que se ajustan serán los de los filtros/kernels que hemos establecido en la capa LSTM [24].
- **5ª capa:** Es la penúltima capa de la red, que se denomina “softmaxLayer”. Conecta con la capa de salida final que tendrá la cantidad de neuronas correspondientes con las clases que estamos clasificando. Por lo tanto, en nuestro experimento como clasificamos NN, NB y NA, serán 3 neuronas [23,24].
- **6ª capa:** Es la última capa de la red, que se denomina “classificationLayer”. Esta capa se encarga de realizar la clasificación de los datos obtenidos de las capas intermedias.

```

126 - | layers = [
127     |     sequenceInputLayer(numFeatures, 'Name', 'sequence')
128     |     lstmLayer(20, 'OutputMode', 'last', 'Name', 'lstm')
129     |     dropoutLayer(0.5, 'Name', 'drop')
130     |     fullyConnectedLayer(numClasses, 'Name', 'fc')
131     |     softmaxLayer('Name', 'softmax')
132     |     classificationLayer('Name', 'classification')];

```

Figura 6. 13. Capas de la Red LSTM

En tercer lugar, vamos a introducir las **opciones de entrenamiento** que hemos establecido para el funcionamiento de la red. Antes de proceder, hemos de precisar que usamos un entrenamiento supervisado, esto es, para cada secuencia de vídeo disponemos de un etiquetado manual como el descrito en el Capítulo 3.

- **Epoch:** Este es el número de veces que se van a pasar cada ejemplo de entrenamiento por la red. Nosotros establecemos un valor de entre 10 y 20, ya que hemos comprobado que es suficiente para que la red aprenda.
- **Batch Size:** Este es el número de ejemplos que se introducen en la red para que entrene de cada vez. Si el número es pequeño, significa que la red tiene en memoria poca cantidad de datos, y entrena más rápido. Sin embargo, es posible que no aprenda las características y detalles que pueden ser significativos en la predicción. En cambio, si es grande es más probable que tenga en cuenta los casos más importantes a la hora de aprender, pero entrena más lento [27]. En nuestro caso, hemos utilizado un número elevado, ya que no nos afecta demasiado el tiempo de ejecución y, además, nos sirve para que la red aprenda numerosos detalles.
- **InitialLearnRate:** Este parámetro controla la tasa o velocidad a la que aprende el modelo. Específicamente, controla la cantidad de error repartido con el que se actualizan los pesos del modelo cada vez que se actualizan, como al final de cada lote de ejemplos de entrenamiento. En el caso de nuestra red, le hemos dado un valor de  $1 \cdot 10^{-4}$ . Esto significa que una tasa de aprendizaje de  $1 \cdot 10^{-4}$ , significaría que los pesos en la red se actualizan  $1 \cdot 10^{-4} \cdot$  (error de peso estimado) o 0.01 % del error de peso estimado cada vez que se actualizan los pesos [26].

- **GradientThreshold:** El recorte de degradado implica forzar los valores del degradado (por elementos) a un valor mínimo o máximo específico si el degradado excedió un rango esperado. En nuestro caso, hemos puesto un valor de 2, lo que significa que si un valor de gradiente fuera menor que -2, se establece en -2 y si es mayor que 2, entonces se configurará en 2 [29].
- **ValidationData:** Este parámetro recoge los niveles de entrenamiento que se van a evaluar (NN, NB y NA) y las diferentes secuencias que se han recogido especificando sus tamaños.
- **ValidationFrequency:** Este parámetro define el número de iteraciones que se van a realizar por cada Epoch. Dicho valor se establece a partir del cociente entre el número de observaciones dividido por el Batch Size.

```

139 -
140
141
142
143
144
145
146
147
148
options = trainingOptions('adam', ...
    'MaxEpochs',maxEpochs,...
    'MiniBatchSize',miniBatchSize, ...
    'InitialLearnRate',1e-4, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'ValidationData',{sequencesTrain,labelsTrain}, ...
    'ValidationFrequency',numIterationsPerEpoch, ...
    'Plots','training-progress', ...
    'Verbose',false);
    
```

Figura 6. 14. Opciones de entrenamiento de la Red LSTM.

Por último, en la siguiente figura vamos a mostrar algunos un análisis que ha realizado la red a la hora de entrenar:

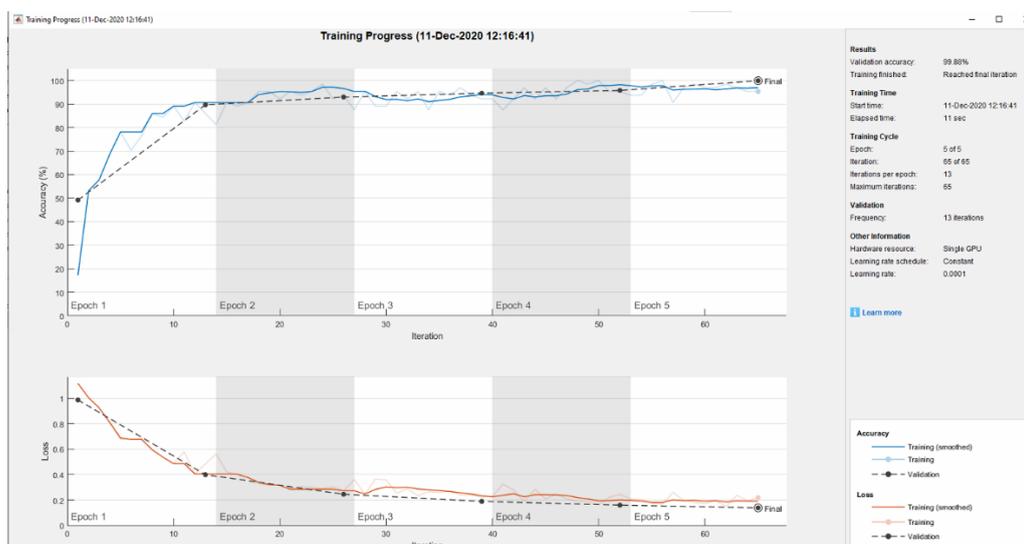


Figura 6. 15. Ejemplo de entrenamiento de una red LSTM en este TFG.

## 6.4 Evaluación de resultados

Este TFG está basado en una serie de técnicas aplicadas de aprendizaje máquina para la detección y cuantificación de lluvia sobre secuencias de vídeo a partir de cámaras de videovigilancia. Por ello, se deben de definir unos parámetros de calidad para la detección [30,31].

### *Parámetros de calidad para la detección*

Para definir los parámetros de calidad para la detección es necesario establecer, inicialmente, una matriz de confusión de 2x2. Donde los parámetros usados en dicha matriz son los siguientes:

- **TP:** en inglés “True Positive” o en castellano “Verdadero Positivo”. Se detecta como lluvia y se ha clasificado como evento de lluvia en la base de datos.
- **FN:** en inglés “False Negative” o en castellano “Falso Negativo”. Se detecta como no lluvia y se ha clasificado como evento de lluvia en la base de datos.
- **TN:** en inglés “True Negative” o en castellano “Verdadero Negativo”. Se detecta no lluvia y se ha clasificado como evento de no lluvia en la base de datos.
- **FP:** en inglés “False Positive” o en castellano “Falso Positivo”. Se detecta lluvia y se ha clasificado como evento de no lluvia en la base de datos.

Recordemos que disponemos de 2 clases en el aprendizaje supervisado de la red neuronal para el proceso de detección:

- **NN:** No hay datos meteorológicos reales de lluvia.
- **NB-NA:** Sí hay datos meteorológicos reales de lluvia.

En la tabla siguiente se muestra los resultados obtenidos en la detección de la precipitación, se trata de una matriz de confusión binaria de tamaño 2x2. Las filas de dicha matriz representan la lluvia real u observada, mientras que las columnas representan la lluvia detectada o su predicción.

		LLUVIA DETECTADA	
		NN	NB-NA
LLUVIA REGISTRADA EN LA BBDD	NN	TN	FP
	NB-NA	FN	TP

Tabla 6. 2. Matriz de confusión binaria para la detección de la eventos de lluvia.

En la tabla se muestra la matriz de confusión anterior, pero con la interpretación de los resultados obtenidos en cada caso. Se dispone de cuatro posibles resultados:

		LLUVIA DETECTADA	
		NN	NB-NA
LLUVIA REGISTRADA EN LA BBDD	NN	Se detecta no lluvia y se ha clasificado como evento de no lluvia.	Se detecta lluvia y se ha clasificado como evento de no lluvia.
	NB-NA	Se detecta como no lluvia y se ha clasificado como evento de lluvia.	Se detecta como lluvia y se ha clasificado como evento de lluvia.

Tabla 6. 3. Matriz de confusión binaria con la interpretación de los resultados obtenidos en la detección de eventos de lluvia.

Para el estudio del rendimiento y la calidad de la detección de la precipitación se ha empleado los siguientes parámetros:

**Exactitud:**

Este parámetro nos proporciona información sobre la proporción entre el número de eventos detectados como verdaderos positivos y verdaderos negativos entre todos los posibles resultados obtenidos. Nos indica la proximidad de la media de una serie de datos al valor que se acepta como verdadero.

**Sensibilidad:**

Este parámetro representa una proporción entre el número de eventos detectados como verdaderos positivos de lluvia entre el número de eventos totales reales u observados positivos de lluvia (hay

datos meteorológicos reales de lluvia). Por lo tanto, este parámetro cuanto mayor sea, más capacidad tendrá de detectar eventos de lluvia.

**Especificidad:**

Este parámetro representa una proporción entre el número de eventos detectados como casos negativos de lluvia entre el número de eventos totales reales u observados negativos de lluvia (datos meteorológicos reales de no lluvia). Nos indica que cuanto mayor sea el valor de este parámetro, más eventos de no lluvia serán detectados correctamente.

**Precisión:**

Este parámetro representa una proporción entre el número de eventos detectados como casos positivos de lluvia entre el número de eventos totales positivos de lluvia. Este parámetro nos indica como de cerca están una de las repeticiones que se realizan por cada cámara.

PARÁMETROS	FÓRMULAS	
<b>Exactitud</b>	$\frac{n^{\circ} \text{ de eventos detectados verdaderos positivos y negativos}}{n^{\circ} \text{ de eventos totales}}$	$\frac{TP + TN}{TP + FN + TN + FP}$
<b>Sensibilidad</b>	$\frac{n^{\circ} \text{ de eventos detectados positivos}}{n^{\circ} \text{ de eventos totales reales positivos}}$	$\frac{TP}{TP + FN}$
<b>Especificidad</b>	$\frac{n^{\circ} \text{ de eventos detectados negativos}}{n^{\circ} \text{ de eventos totales reales negativos}}$	$\frac{TN}{TN + FP}$
<b>Precisión</b>	$\frac{n^{\circ} \text{ de eventos detectados positivos}}{n^{\circ} \text{ de eventos totales positivos}}$	$\frac{TP}{TP + FP}$

Tabla 6. 4. Formulación de cada uno de los parámetros de calidad.

***Parámetros de calidad para la cuantificación***

***Análisis general de eventos de lluvia***

Para medir los parámetros de calidad para la cuantificación es necesario ampliar la matriz de confusión a un tamaño de 3x3.

En este momento disponemos de 3 clases en el aprendizaje supervisado de la red neuronal:

- **NN:** No hay datos meteorológicos reales de lluvia y el nivel de precipitación es nulo.
- **NB:** Si hay datos meteorológicos reales de lluvia y el nivel de precipitación es bajo.
- **NA:** Si hay datos meteorológicos reales de lluvia y el nivel de precipitación es alto.

En la tabla 6.5 se muestra los resultados obtenidos en la detección de la precipitación, se trata de una matriz de confusión de tamaño 3x3. Las filas de dicha matriz representan la lluvia real u observada, mientras que las columnas representan la lluvia detectada o su predicción.

		LLUVIA DETECTADA		
		NN	NB	NA
LLUVIA REGISTRADA EN LA BBDD	NN	TN	FP	FP
	NB	FN	TP	TP
	NA	FN	TP	TP

Tabla 6. 5. Matriz de confusión 3x3 para la detección de eventos de lluvia.

En la tabla 6.6 se muestra la matriz de confusión anterior, pero con la interpretación de los resultados obtenidos en cada caso. Se dispone de nueve posibles resultados:

		LLUVIA DETECTADA		
		NN	NB	NA
LLUVIA REGISTRADA EN LA BBDD	NN	Se detecta no lluvia y se ha clasificado como evento de no lluvia.	Se detecta lluvia y se ha clasificado como evento de no lluvia.	Se detecta lluvia y se ha clasificado como evento de no lluvia.
	NB	Se detecta como no lluvia y se ha clasificado como evento de lluvia.	Se detecta como lluvia y se ha clasificado como evento de lluvia.	Se detecta como lluvia y se ha clasificado como evento de lluvia.
	NA	Se detecta como no lluvia y se ha clasificado como evento de lluvia.	Se detecta como lluvia y se ha clasificado como evento de lluvia.	Se detecta como lluvia y se ha clasificado como evento de lluvia.

Tabla 6. 6. Matriz de confusión 3x3 con la interpretación de los resultados obtenidos en la detección de eventos de lluvia.

Como se puede observar en la tabla 6.6 de la matriz de confusión el sistema indica si se ha detectado lluvia o no, y su grado de acierto es medible mediante los parámetros antes descritos. Pero, con estos datos no se sabe si la clasificación realizada es correcta para todos los casos, por ejemplo, supongamos que hay datos meteorológicos reales de lluvia, esta lluvia detectada puede ser baja o alta, el sistema sólo nos indica que se ha detectado dicha lluvia, pero no su nivel. Al igual que tampoco sabemos la fiabilidad de los resultados obtenidos en la detección. Por esta razón necesitamos un sistema que nos ayude a cuantificar el nivel de lluvia de forma correcta.

		LLUVIA DETECTADA		
		NN	NB	NA
LLUVIA REGISTRADA EN LA BBDD	NN	TN	FP	FP
	NB	FN	TP	TP
	NA	FN	TP	TP

Tabla 6. 7. Matriz de confusión para la detección de la eventos de lluvia.

El problema de este análisis es que no podemos apreciar la diferencia entre eventos de lluvia a nivel bajo y a nivel alto, ya que lo que clasificamos es directamente la diferencia entre eventos de no lluvia y eventos de lluvia, sin poder ofrecer una clasificación que también diferencia ambos eventos de lluvia.

### *Análisis específico de eventos de lluvia*

Como solución a la problemática expuesta en el apartado anterior, a través de la misma matriz de confusión 3x3, hemos podido realizar un estudio más preciso de la diferencia que existe entre eventos de lluvia a nivel bajo y nivel alto, sin tener que realizar ningún calculo diferente sino utilizando una función en Matlab que nos genera automáticamente la distinción de ambas clases.

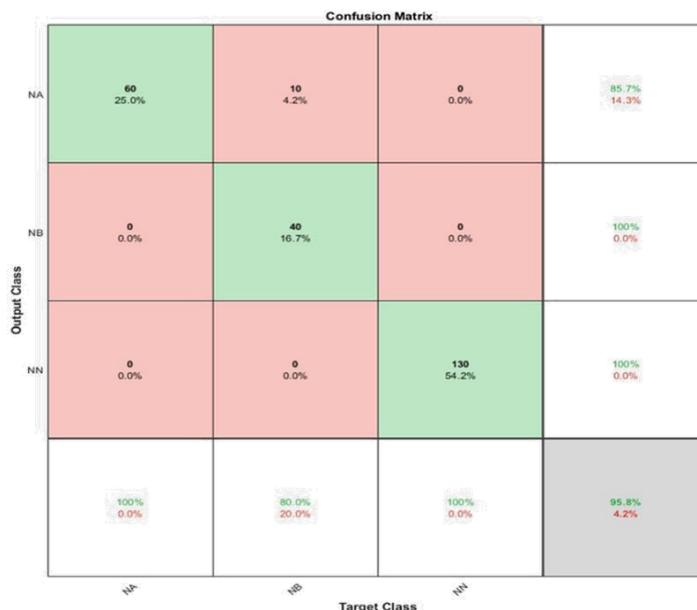


Figura 6. 16. Prueba gráfica de la función “confusionchart “ de MATLAB.

Esta función nos permite en cada evento visualizar el comportamiento de la red para cada una de las clases ofreciendo porcentajes de acierto para cada una de ellas y demostrando que en general, este sistema también diferencia bastante bien eventos de lluvia a nivel bajo y a nivel alto, lo que nos resuelve las dudas planteadas en el apartado anterior.

### 6.5 Clasificación de los resultados

Los datos que la red nos proporciona los almacenamos en un archivo Excel como el mostrado en la figura 6.17.

		Resultados estadísticos a partir de TN, TP, FN y FP				Lectura de los resultados de la red. Matriz de Confusión			
		A	B	C	D	E	F	G	H
		Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
Número de repeticiones del experimento	1	100,00	100,00	100,00	100,00	110	0	0	60
	2	100,00	100,00	100,00	100,00	110	0	0	150
	3	100,00	100,00	100,00	100,00	190	0	0	70
	4	100,00	100,00	100,00	100,00	120	0	10	130
	5	96,15	92,86	100,00	100,00	140	0	0	120
	6	100,00	100,00	100,00	100,00	156	24	0	80
	7	100,00	100,00	100,00	100,00	180	0	0	80
	8	100,00	100,00	100,00	100,00	210	0	0	50
	9	100,00	100,00	100,00	100,00	160	0	0	100
	10	100,00	100,00	100,00	100,00	180	0	0	80
	11	100,00	100,00	100,00	100,00	120	0	0	110
	12	100,00	100,00	100,00	100,00	180	0	0	50
	13	100,00	100,00	100,00	100,00	160	0	0	70
	14	100	100	100	100	110	0	0	140
	15	100	100	100	100	150	0	0	100
	16	100	100	100	100	110	0	0	140
	17	100	100	100	100	140	0	0	110
	18	100	100	100	100	210	0	0	40
	19	100	100	100	100	190	0	0	60
	20	100	100	100	100	210	0	0	40
	21	100	100	100	100	110	0	0	100
	22	100	100	100	100				

Figura 6. 17. Resultados en Excel de la cámara Hospital1-Barrancoseco.

Las filas del fichero Excel representan el número de repeticiones que se han realizado para evaluar el funcionamiento de la red para una determinada cámara, evaluando en cada repetición secuencias de forma aleatoria, lo cual aumenta nuestro nivel de precisión y calidad.

Por otro lado, las columnas E-H, representa el número de fotogramas que la red ha evaluado en función de los parámetros TN, FN, VN y FP.

Por último, las columnas A-D nos presentan resultados estadísticos en función de los datos recogidos por la red, por lo tanto, a partir de los datos de las otras 4 columnas.

## ***6.6 Criterios para realizar los experimentos***

En este apartado vamos a describir los parámetros que hemos establecido para la realización satisfactoria de los experimentos.

- **Elección entre un modelo por cámaras o un modelo general para todas las cámaras:** La elección del primer modelo haría que utilizáramos la red LSTM para cada una de las cámaras de forma individual mientras que el segundo modelo se realiza a partir del estudio conjunto de todas las cámaras por parte de la red para posteriormente realizar la evaluación.
- **Preprocesado de la imagen:** En nuestro caso, vamos a realizar un preprocesado de la imagen utilizando el Filtro Sobel, el cual explicamos el motivo de su elección en el capítulo 3 de este TFG.
- **Balance de datos para entrenar y clasificar:** Debemos tener en cuenta que normalmente para este tipo de experimentos se debe trabajar entre el 70% y 80% en el entrenamiento, el cual podremos definir de forma diferente en función de la elección entre los modelos que hemos comentado anteriormente, debido a que la cantidad de datos no es la misma.
- **Base de datos equilibrada:** La creación y la organización de la base de datos para la detección y la cuantificación de la precipitación de la lluvia se detalla en el capítulo 3 de este TFG. La estructura de la base de datos debe de ser equilibrada para que la red pueda

evaluar diferentes eventos a partir del entrenamiento de eventos de lluvia y no lluvia para que adquiriera conocimientos de ambos estados.

- **Elección de la ROI:** A partir de la ROI que se ha utilizado en el TFG que nos sirve como base, teniendo en cuenta que se utilizaba para evaluar fotograma a fotograma, podríamos tener que cambiar la ROI para el análisis de secuencias de vídeo, ya que puede funcionar de forma diferente.
- **Técnica leave-1-out:** En esta técnica de selección para entrenamiento sacamos una secuencia de las disponibles y, que será usada para testear, y entrenamos la red con las demás. El proceso se repite tantas veces como secuencias tenemos. La utilizaríamos en el modelo por cámaras para evaluar el correcto funcionamiento de cada secuencia, eligiendo cuál queremos que evalúe la red y localizando qué secuencias están obteniendo buenos resultados y cuales están generando falsos positivos o negativos. Esto nos ayudaría a elegir otros criterios como la elección de la ROI que se podría cambiar para mejorar el rendimiento de la red.
- **Red LSTM:** Los detalles de la red neuronal convolucional se detallan en el capítulo 5 de este TFT.

Esta red se basa en una serie de algoritmos que se engloban en dos grandes bloques: Test y Entrenamiento.

El objetivo es la obtención de un modelo de aprendizaje máquina LSTM entrenado que sea capaz de detectar si hay lluvia o no, y en el caso de disponer de lluvia realizar una cuantificación de la precipitación.

Como se ha detallado en el capítulo 6 en el apartado de las métricas de calidad, este TFT se ha realizado mediante un aprendizaje supervisado formado por 3 clasificaciones:

- **NN:** No hay datos meteorológicos reales de lluvia y el nivel de precipitación es nulo.
- **NB:** Si hay datos meteorológicos reales de lluvia y el nivel de precipitación es bajo.
- **NA:** Si hay datos meteorológicos reales de lluvia y el nivel de precipitación es alto.

En cuanto a las capas que conforman la red, se ha optado por el uso de 6 capas. Estas capas las hemos utilizado desde el primer experimento y no hemos realizado ningún cambio, ya que es así como podemos trabajar con series temporales en una red LSTM.

- **Calidad de los datos:** La calidad de los datos recogidos se detalla en el capítulo 3 de este TFT. Los datos que hemos utilizado para obtener los resultados anteriores han sido:
  - **Número de fotogramas/segundo:** 10 o 20 fotogramas/segundo.
  - **Duración de la secuencia o vídeo:** 2 segundos.
  - **Ancho del fotograma:** 1280.
  - **Alto del fotograma:** 720.

Hemos llegado a la conclusión de que utilizando 10 fotogramas podemos obtener unos resultados realmente buenos teniendo en cuenta que hemos realizado pruebas con 25, y nos ha supuesto un aumento del número de muestras que la red evalúa, pero conlleva un tiempo de ejecución más largo y los resultados se mantiene en los mismos valores que con 10 fotogramas.

- **Métricas de calidad:** Los parámetros de calidad para la detección de la precipitación de la lluvia están recogidos anteriormente en este capítulo 6 de este TFT.

Para el estudio de la calidad para la detección era necesario establecer una matriz de confusión de 3x3 donde las filas de dicha matriz representan los eventos de lluvia clasificados en la BBDD, mientras que las columnas representan la lluvia detectada por la red. Una vez establecida dicha matriz se procede a estudiar el rendimiento e interpretar la calidad de la detección de la precipitación mediante los parámetros de: exactitud, precisión, sensibilidad y especificidad y la distinción entre eventos de lluvia a nivel bajo y a nivel alto.

## 6.7 Experimentos de detección y cuantificación. Resultados

El desarrollo y experimentación de este TFT se realizó en dos bloques de estudio diferentes:

- **El bloque de la detección:** En este bloque el objetivo era obtener un clasificador binario, que detectara si había precipitación de lluvia real o no.

En este mismo bloque realizamos un estudio de pre-procesado o pre-extracción de características que nos ayudara a mejorar la calidad de los datos obtenidos y así mejorar los resultados finales. Posteriormente se calcularon los parámetros de calidad para la detección (Exactitud, precisión, sensibilidad y especificidad).

- **El bloque de la cuantificación:** En este bloque ampliamos la matriz de confusión del bloque de detección y añadimos 3 clases al clasificador de la red neuronal. Ahora no sólo se detectaba la presencia o ausencia de lluvia, sino que además se clasificaba en tres niveles de lluvia (no lluvia, lluvia baja y lluvia alta).

En este TFT se ha optado por el uso de una red LSTM de 6 capas intermedias u ocultas y un aprendizaje supervisado de 3 clasificaciones. Para la elección del número de capas, inicialmente hemos realizado un preprocesado, donde realizamos experimentos tales como extracción de regiones de interés y filtrado de Sobel. Una vez estudiado y seleccionado el bloque de preprocesado, se procedió a estudiar el número de capas mínimas necesarias para la red, con la finalidad de obtener unos resultados óptimos.

Realizamos todos los experimentos teniendo en cuenta:

- Imágenes con lluvia y sin lluvia.
- Diferentes cámaras de videovigilancia.
- Diferentes momentos del día (noche y día)



# CAPÍTULO 7: IMPLEMENTACIÓN DEL MÉTODO DE DETECCIÓN Y CUANTIFICACIÓN

En los capítulos anteriores hemos explicado el preprocesado de la señal recibida (capítulo 4), el marco metodológico (capítulo 5) y el método de detección y cuantificación (capítulo 6). En este capítulo se expone el algoritmo que hemos utilizado para detectar y cuantificar el nivel de precipitación de lluvia a partir de secuencias de vídeo recibidas desde diferentes cámaras de videovigilancia.

Una vez hemos observado en el capítulo 6 el esquema general de cómo funciona el proyecto, vamos a explicar como lo hemos implementado y programado:

```

clc
close all;
clear all;

% PARÁMETROS DEL PROGRAMA, COMUNES A TODOS LOS EXPERIMENTOS
%____training____

% Filtrado de Sobel
Filt_Sobel = 1;           % =0, no filtra Sobel; = 1, sí filtra Sobel
Size_Sobel = 3;          % Tamaño de los filtros de Sobel, genera una
matriz Size_Sobel x Size_Sobel
[Mx,My]      = GSobel_Filters(Size_Sobel);
Borde_Sobel = fix(Size_Sobel/2); % Al aplicar conv2 para filtrar se generan píxeles
extra que no hacen falta.
ancho        = 400;
alto         = 200;
targetSize = [alto ancho];
%Para el fichero excel
numeroExperimento= '10frames-TF4-Prueball'; %----->
CAMBIAR EN CADA EXPERIMENTO EL NUMERO <-----
filename=strcat('resultados_',numeroExperimento,'.xlsx');
% A = {'Accuracy (Exactitud)', 'Sensibilidad (Sensibilidad)', 'Specificity
(Especificidad)', 'Precision (Precisión)'};
A = {'Exactitud', 'Sensibilidad', 'Especificidad', 'Precisión'};
B = {'TN', 'FP', 'FN', 'TP'};
Ini_Iter = 1;
Fin_Iter = 10;

```

Figura 7. 1. Primera parte de explicación del algoritmo de detección y cuantificación.

En esta primera parte del script podemos observar que lo que hacemos es establecer las condiciones en las que vamos a generar el archivo Excel con los datos que obtengamos al final de código. Podemos observar que le damos nombre al archivo, ponemos los valores que vamos a almacenar en un rango A y B y, por último, establecemos el número de repeticiones que queremos realizar en nuestro experimento.

```

for r=Ini_Iter:Fin_Iter
    inputFolderVideo = [pwd '\ 'Videovigilancia_Secuencial' ]; %directorio para
acceder a los video
    Experimentos_Camaras = readtable('Camaras_1C.csv','Delimiter',';'); %leemos el
contenido de 'experimentos_Camaras.csv' y creamos una tabla con los datos leidos
    %Experimentos_Camaras = readtable('Camaras_NN.csv'); %leemos el contenido de
'experimentos_Camaras.csv' y creamos una tabla con los datos leidos

    [Ic,Jc]      = size(Experimentos_Camaras);
    NumerodeFrames = 10;
    DD          = dir(inputFolderVideo);
    [ID,JD]     = size(DD);
    Scores      = zeros(Ic,2,2);
    Scores_Copia = zeros(1,4);
    ScoresC     = zeros(Ic,2,2);
    ScoresC_Copia = zeros(1,4);

    %% ____training____
    %    hojal = r; %recuerda que cada hoja del excel guarda los resultados
hojal = 1; %recuerda que cada hoja del excel guarda los resultados
    if (r==1)
        Rango1 = ['A' num2str(r) ':' 'D' num2str(1)];
        Rango2 = ['E' num2str(r) ':' 'H' num2str(1)];
        xlswrite(filename,A,hojal,Rango1);
        xlswrite(filename,B,hojal,Rango2);
    end

    filal=2; %luego dentro del bucle irá cambiando
    fila2=13; %luego dentro del bucle irá cambiando
    Sec_Train      = 0.8; % Porcentaje de secuencias para entrenamiento, resto

```

Figura 7. 2. Segunda parte de explicación del algoritmo de detección y cuantificación.

En este caso en función del número de iteraciones que hemos comentado anteriormente, establecemos la forma de acceder a la base de datos la cual se llama, “Videovigilancia\_Secuencial”, y a través de un Excel que nosotros generamos como este:

	A
1	Camaras
2	Hospital1-Barranquense
3	Hospital2-Catedral
4	Hospital3-Isleta
5	Hospital4-Escaleritas
6	Tafira1-Informatica
7	Tafira2-MontanaArucas
8	Tafira3-FOSCAM
9	Tafira4-FOSCAM

Tabla 7. 1. Cámaras que se evaluarán en el experimento.

Con este documento que se llama “Camaras\_NN”, colocamos el nombre de las cámaras que queremos evaluar. Por lo tanto, solo se evaluarán las cámaras que coincidan en el Excel y la base de datos.

Por otro lado, escogemos las variables de tamaño que nos interesa saber para poder recorrer posteriormente la base de datos, hemos establecido parámetros como el número de frames que vamos a recoger por vídeo, hemos establecido la condición para que si es la primera secuencia genere los parámetros que va a almacenar el Excel y establecemos el valor que le vamos a dar al entrenamiento.

```

for cc=1:Ic % Procesamos mientras que tengamos camaras a seleccionar en
'Camaras_NN.csv'
    Camara_t      = Experimentos_Camaras(cc,1); %Tabla con todas las camaras del
experimento
    Camara        = Camara_t.Camaras{:}; %Extraemos nombres de camaras en cadena
(sin tabla)
    inputFolderVideo = [pwd '\ ' 'Videovigilancia_Secucional' '\ ' Camara]; %
directorio para acceder a los videos de una determinada camara.
    DD            = dir(inputFolderVideo);
    [ID,JD]       = size(DD);
    ID_Secs       = (ID-2);
    Num_Secs_Tr   = round(Sec_Train*ID_Secs);
    Indic_Sec     = randperm(ID_Secs);
    Indic_Train   = Indic_Sec(1:Num_Secs_Tr);
    % SECUENCIAS DE TRAIN
    sseq_tr       = 1;
    inputDir       = inputFolderVideo;
    DD2           = dir(inputDir);
    [ID2,JD2]     = size(DD2);

```

```

    for kk=Indic_Train % ... recorrer los directorios de cada
secuencia...
        inputVideovigilanciaSecuencial = DD2(kk+2).name;
        DD3 = dir([inputDir '\' inputVideovigilanciaSecuencial]);
        [ID3,JD3] = size(DD3);
        for jj=1:(ID3-2) % ... y procesar cada video
            inputFileVideo = DD3(jj+2).name;
            inputFullFileVideo = fullfile([inputDir '\'
inputVideovigilanciaSecuencial],inputFileVideo);
            video = readVideo(inputFullFileVideo);
            for il = 1:NumerodeFrames % Extracción de los frames en cada
video
                frame = video(:,:,il);

                Procesado_Imagen_prueba2;
                frame_vec = frame_lum;
                frame_vec = frame_vec(:);

                sequencesTrain(sseq_tr,1) = {frame_vec};
                labelsTrain(sseq_tr,1) = {inputFileVideo(end-5:end-4)};
                sseq_tr = sseq_tr + 1;
                clear frame frame_vec frame_lum I2 frame1
            end
        end
    end
    labelsTrain = categorical(labelsTrain);

```

Figura 7. 3. Tercera parte de explicación del algoritmo de detección y cuantificación.

En este apartado lo que realizamos es el estudio de todas las cámaras que queramos evaluar, escogiendo el directorio en el que están. Por otro lado, una vez ya estamos dentro de la carpeta donde se almacenan las secuencias, lo que hacemos es estudiar las secuencias de forma aleatoria y no por orden para que, a la hora de evaluar, la red no escoja siempre las mismas secuencias. Posteriormente, leemos los vídeos y sacamos 10 frames de cada uno de los vídeos. El paso siguiente una vez tenemos las imágenes, es realizar el preprocesado de esas imágenes antes de que sean evaluadas por la red. Podemos ver señalada en la imagen el archivo “Procesado\_Imagen\_prueba2”, el cual se encarga de esta parte:

```

[fil,col,prof] = size(frame);
frame1 = frame;
switch Camara
    case 'Tafiral-Informatica'
        % Segmento n° 8:
        %I2 = imcrop(frame1/255,[(col-1)/3 ((fil-1)/3)*2 ((col-1)/3) (fil-
1)/3]);
        % Segmento n° 5:
        I2 = imcrop(frame1/255,[(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);

```

```

        case 'Tafira3-FOSCAM'
            % Segmento n° 8
            %I2 = imcrop(frame1/255, [(col-1)/3 ((fil-1)/3)*2 ((col-1)/3)
(fil-1)/3]);
            % Segmento n° 4
            I2 = imcrop(frame1/255, [0 (fil-1)/3 ((col-1)/3) (fil-1)/3]);
            % Segmento n° 5:
            %I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);

        case 'Hospital1-Barrancoseco'
            % Segmento n° 4:
            I2 = imcrop(frame1/255, [0 (fil-1)/3 ((col-1)/3) (fil-1)/3]);
        case 'Hospital2-Catedral'
            % Segmento n° 9:
            I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);
            %I2 = imcrop(frame1/255, [(col-1)/3)*2 ((fil-1)/3)*2 ((col-1)/3)
(fil-1)/3]);
        case 'Hospital3-Isleta'
            % Segmento n° 9
            %I2 = imcrop(frame1/255, [(col-1)/3)*2 ((fil-1)/3)*2 ((col-1)/3)
(fil-1)/3]);
            % Segmento n° 8
            %I2 = imcrop(frame1/255, [(col-1)/3 ((fil-1)/3)*2 ((col-1)/3)
(fil-1)/3]);
            % Segmento n° 5:
            I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);
        case 'Hospital4-Escaleritas'
            % Segmento n° 8:
            %I2 = imcrop(frame1/255, [(col-1)/3 ((fil-1)/3)*2 ((col-1)/3) (fil-
1)/3]);
            % Segmento n° 5:
            I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);
        case 'Tafira2-MontanaArucas'
            % Segmento n° 5:
            I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);
            % Segmento n° 8:
            %I2 = imcrop(frame1/255, [(col-1)/3 ((fil-1)/3)*2 ((col-1)/3) (fil-
1)/3]);
        case 'Tafira4-FOSCAM'
            % Segmento n° 4:
            I2 = imcrop(frame1/255, [0 (fil-1)/3 ((col-1)/3) (fil-1)/3]);
            % Segmento n° 8:
            I2 = imcrop(frame1/255, [(col-1)/3 ((fil-1)/3)*2 ((col-1)/3)
(fil-1)/3]);
        otherwise
            %si es otra cámara se coje por defecto segmento n°5
            I2 = imcrop(frame1/255, [(col-1)/3 (fil-1)/3 ((col-1)/3) (fil-1)
/3]);
    end

```

Figura 7. 4. Primera parte de explicación del algoritmo “Procesado\_Imagen\_prueba2”.

En esta parte del procesado de imagen, lo que hacemos es escoger la mejor ROI para cada una de las cámaras. Podemos comprobar que se han utilizado diferentes ROIs en busca de la que nos aporte mejores resultados y mayor precisión.

```

%targetSize = [240 420];
r2 = centerCropWindow2d(size(I2),targetSize);
I2 = imcrop(I2,r2);

%
end
%Pasamos la imagen a espacio de color lab (CIELAB)

% Filtrado de Sobel-----
if (Filt_Sobel==1)
    [Is,Js,Ks] = size(I2);
    I2_b      = I2;
    for ss=1:Ks
        if (Filt_Sobel==1)
            Cx      = conv2(I2_b(:,:,ss),Mx);
            Cy      = conv2(I2_b(:,:,ss),My);
            I2(:,:,ss) = max(Cx(Borde_Sobel+1:end-Borde_Sobel,
Borde_Sobel+1:end-Borde_Sobel),Cy(Borde_Sobel+1:end-Borde_Sobel,
Borde_Sobel+1:end-Borde_Sobel));
        end
    end
    % Guardo imagen del filtro Sobel:
    Dir_RGB3      = ['Segmentación RGB y SOBEL' '\ ' Camara '\ ' DD(kk+2).
name]; %Creamos la dirección: Luminancia
    DD_RGB3      = dir(Dir_RGB3); %Cargo lo que contiene la carpeta
para verificar si esta creada la carpeta temporal
    if ( isempty(DD_RGB3) ) %Si la carpeta temporal no está creada la
creamos.
        mkdir(Dir_RGB3);
    end
    outputBaseFileName = sprintf('Frame_%4.4d_video_%d.png', i1,jj);
    outputFullFileName = fullfile(Dir_RGB3, outputBaseFileName);
    imwrite(I2, outputFullFileName, 'png');
end
end

```

Figura 7. 5 Segunda parte de explicación del algoritmo “Procesado\_Imagen\_prueba2”.

Una vez tenemos la ROI que queremos, establecemos un tamaño fijo para todas las imágenes que se generen independientemente de la región que sea, ya que puede que no todas las regiones tengan el mismo tamaño lo que nos puede ocasionar un problema a la hora de que sea evaluado por la red, ya que desde que detecte tamaños diferentes no funciona.

Por otro lado, realizamos el filtro de Sobel y guardamos cada una de las imágenes generadas.

```

% %-----TRAINING-----
% opcion='L';

% Load the digit sample data as an image datastore.

if (Filt_Sobel == 1) %si filtro SOBER
    switch opcion
        case {'L','l'}
            cad='Segmentación Luminancia y SOBEL';
        case {'C','c'}
            cad='Segmentación RGB y SOBEL';
    end
end

```

```

else %No filtro SOBER
    switch opcion
        case {'L','l'}
            cad='Segmentación Luminancia';
        case {'C','c'}
            cad='Segmentación RGB';
        end

    % Integrar en una sola capa (¿luminancia?) =>
end
frame_lum= 0.3*I2(:,:,1) + 0.59*I2(:,:,2) + 0.11*I2(:,:,3);

```

Figura 7. 6. Tercera parte de explicación del algoritmo “Procesado\_Imagen\_prueba2”.

Por último, elegimos este tipo de imágenes para entrenar la red e integramos en una sola capa para posteriormente convertir en un vector la imagen que se ha generado, que es lo que realmente entrará en la red.

Ahora volvemos de nuevo al código principal:

```

    % SECUENCIAS DE TEST - Procesado igual que en TRAIN pero con otras
secuencias
    sseq_ts      = 1;
    %inputDir    = inputFolderVideo;
    %DD2        = dir(inputDir);
    %[ID2,JD2]  = size(DD2);
    Indic_Test  = Indic_Sec(Num_Secs_Tr+1:end);
    %           for kk=(Num_Secs_Tr+1):(ID2-2)
for kk=Indic_Test
    inputSecsVideo = DD2(kk+2).name;
    DD3            = dir([inputDir '\\' inputSecsVideo]);
    [ID3,JD3]     = size(DD3);
    for jj=1:(ID3-2)
        inputFileVideo = DD3(jj+2).name;
        inputFullFileVideo = fullfile([inputDir '\\' inputSecsVideo],
inputFileVideo);
        video          = readVideo(inputFullFileVideo);
        for i1 = 1:NumerodeFrames
            frame      = video(:,:,i1);
            Procesado_Imagen_prueba2;
            frame_vec  = frame_lum;
            frame_vec  = frame_vec(:);

```

```

sequencesValidation(sseq_ts,1) = {frame_vec};
labelsValidation(sseq_ts,1)   = {inputFileVideo(end-5:end-4)};

sseq_ts                        = sseq_ts + 1;
clear frame frame_vec frame_lum I2 frame1
    end
end
end

```

Figura 7. 7. Cuarta parte de explicación del algoritmo de detección y cuantificación.

Una vez lo convertimos en vector, se registran los niveles de entrenamiento que se recogen que son: NN, NA y NB. Por otro lado, realizamos el mismo procedimiento para las secuencias que van a ser realmente evaluadas por la red, ya que las anteriores servirán para su entrenamiento.

```

labelsValidation = categorical(labelsValidation);

numFeatures = size(sequencesTrain{1},1);
numClasses = numel(unique(labelsTrain));

layers = [
    sequenceInputLayer(numFeatures, 'Name', 'sequence')
    lstmLayer(20, 'OutputMode', 'last', 'Name', 'lstm')
    dropoutLayer(0.5, 'Name', 'drop')
    fullyConnectedLayer(numClasses, 'Name', 'fc')
    softmaxLayer('Name', 'softmax')
    classificationLayer('Name', 'classification')];

miniBatchSize = 64;
numObservations = numel(sequencesTrain);
numIterationsPerEpoch = floor(numObservations / miniBatchSize);
maxEpochs = 10;

options = trainingOptions('adam', ...
    'MaxEpochs',maxEpochs,...
    'MiniBatchSize',miniBatchSize, ...
    'InitialLearnRate',1e-4, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'ValidationData',{sequencesTrain,labelsTrain}, ...
    'ValidationFrequency',numIterationsPerEpoch, ...
    'Plots','training-progress', ...
    'Verbose',false);

[netLSTM,info] = trainNetwork(sequencesTrain,labelsTrain,layers,options);
YPred = classify(netLSTM,sequencesValidation,'MiniBatchSize',miniBatchSize);
YValidation = labelsValidation;
accuracy = mean(YPred == YValidation)

```

Figura 7. 8. Quinta parte de explicación del algoritmo de detección y cuantificación.

Aquí tenemos las capas de las que se compone la red y las opciones de entrenamiento, las cuales están explicadas en el capítulo 6 de esta memoria.

```

TP          = 0; % True positive,   rain detected as rain
FP          = 0; % False positive,  no-rain detected as rain
TN          = 0; % True negative,   no-rain detected as no-rain
FN          = 0; % False negative,  rain detected as no-rain
Itest      = length(YValidation);
Matriz_Conf = zeros(3,3);
for jj=1:Itest
    if      ( (strcmp(char(YPred(jj)), 'NN')) && (strcmp(char(YValidation
(jj)), 'NN')) )
        TN = TN+1;
        Matriz_Conf(1,1) = Matriz_Conf(1,1) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NB')) && (strcmp(char(YValidation
(jj)), 'NN')) )
        FP = FP+1;
        Matriz_Conf(1,2) = Matriz_Conf(1,2) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NA')) && (strcmp(char(YValidation
(jj)), 'NN')) )
        FP = FP+1;
        Matriz_Conf(1,3) = Matriz_Conf(1,3) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NN')) && (strcmp(char(YValidation
(jj)), 'NB')) )
        FN = FN+1;
        Matriz_Conf(2,1) = Matriz_Conf(2,1) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NB')) && (strcmp(char(YValidation
(jj)), 'NB')) )
        TP = TP+1;
        Matriz_Conf(2,2) = Matriz_Conf(2,2) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NA')) && (strcmp(char(YValidation
(jj)), 'NB')) )
        TP = TP+1;
        Matriz_Conf(2,3) = Matriz_Conf(2,3) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NN')) && (strcmp(char(YValidation
(jj)), 'NA')) )
        FN = FN+1;
        Matriz_Conf(3,1) = Matriz_Conf(3,1) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NB')) && (strcmp(char(YValidation
(jj)), 'NA')) )
        TP = TP+1;
        Matriz_Conf(3,2) = Matriz_Conf(3,2) + 1;
    elseif ( (strcmp(char(YPred(jj)), 'NA')) && (strcmp(char(YValidation
(jj)), 'NA')) )
        Matriz_Conf(3,3) = Matriz_Conf(3,3) + 1;
        TP = TP+1;
    end
end
end

```

Figura 7. 9. Sexta parte de explicación del algoritmo de detección y cuantificación.

Una vez la red ha evaluado las secuencias, vamos a generar los resultados que se van a almacenar en Excel, estableciendo las condiciones necesarias para que se sume a cada tipo: TP, TN, FP y FN en función de la etiqueta que nosotros le hemos puesto y el nivel de evaluación que la red ha definido.

```

    Scores(cc,1,1) = 100*(TN + TP)/(TN+TP+FN+FP); % Accuracy (Exactitud)
    Scores(cc,1,2) = 100*TP/(TP + FN); % Sensitivity
(Sensibilidad)
    Scores(cc,2,1) = 100*TN/(TN + FP); % Specificity
(Especificidad)
    Scores(cc,2,2) = 100*TP/(TP + FP); % Precision (Precisión)

    Scores_Copia(1) = Scores(cc,1,1);
    Scores_Copia(2) = Scores(cc,1,2);
    Scores_Copia(3) = Scores(cc,2,1);
    Scores_Copia(4) = Scores(cc,2,2);

    ScoresC(cc,1,1) = TN; %verdaderos negativos
    ScoresC(cc,1,2) = FP; %falsos positivos
    ScoresC(cc,2,1) = FN; %falsos negativos
    ScoresC(cc,2,2) = TP; %verdaderos positivos

    ScoresC_Copia(1)=ScoresC(cc,1,1);
    ScoresC_Copia(2)=ScoresC(cc,1,2);
    ScoresC_Copia(3)=ScoresC(cc,2,1);
    ScoresC_Copia(4)=ScoresC(cc,2,2);

    %Guardamos los resultados en un fichero excel:
    %RECUERDA ACTUALIZAR 'numeroExperimento' EN EL INICIO DEL ARCHIVO

    Rangol = ['A' num2str(r+cc) ':' 'D' num2str(r+cc)];
    Rango2 = ['E' num2str(r+cc) ':' 'H' num2str(r+cc)];
    xlswrite(filename,Scores_Copia,hoja1,Rangol)
    xlswrite(filename,ScoresC_Copia,hoja1,Rango2)
    fila1=fila1+1;
    fila2=fila2+1;
end
end

```

Figura 7. 10. Séptima parte de explicación del algoritmo de detección y cuantificación.

Por último, esos datos que hemos almacenado, ahora vamos a pasarlo a la hoja Excel que hemos creado a principio de este código para presentar un resultado como este:

	A	B	C	D	E	F	G	H
1	Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
2	100,00	100,00	100,00	100,00	90	0	0	90
3	100,00	100,00	100,00	100,00	100	0	0	130
4	100,00	100,00	100,00	100,00	130	0	0	100
5	100,00	100,00	100,00	100,00	120	0	0	110
6	100,00	100,00	100,00	100,00	110	0	0	120
7	99,57	99,09	100,00	100,00	120	0	1	109
8	98,70	97,50	100,00	100,00	110	0	3	117
9	100,00	100,00	100,00	100,00	100	0	0	130
10	99,13	100,00	98,57	97,83	138	2	0	90
11	100,00	100,00	100,00	100,00	130	0	0	100

Figura 7. 11. Resultados del experimento en Excel.



# CAPÍTULO 8: RESULTADOS FINALES DE LOS EXPERIMENTOS

En este capítulo, después de haber desglosado cada una de las partes de este proyecto en los capítulos anteriores, vamos a exponer los resultados que obtenemos finalmente.

Para ello vamos a dividir dichos resultados en dos grupos y acabamos con una comparativa.

- Modelo general
- Modelo individual

En cada grupo se han realizado 50 repeticiones en las que se ha cogido aleatoriamente los vídeos de entrenamiento (80% para modelo individual, 70% para modelo general) y test (20%,30%) teniendo en cuenta que los vídeos que entrenaban no participan en el test. La finalidad de estas repeticiones es estudiar la robustez de nuestros modelos frente a situaciones realistas, y lo hacemos cambiando repetidas veces las condiciones de entrenamiento y test.

## *8.1 Modelo general*

En este primer apartado, vamos a exponer las métricas de calidad que hemos obtenido a partir del análisis de los fotogramas que hemos preprocesado de forma conjunta, es decir, la red se encargará de realizar el entrenamiento y el test utilizando todas las cámaras simultáneamente para posteriormente clasificar esos fotogramas.

Los resultados que hemos obtenido los podemos observar en la siguiente figura:

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	170	0	0	160
100,00	100,00	100,00	100,00	190	0	0	140
96,94	100,00	94,76	93,17	199	11	0	150
96,67	100,00	93,33	93,75	168	12	0	180
96,94	100,00	94,76	93,17	199	11	0	150
97,22	100,00	94,74	94,44	180	10	0	170
97,22	100,00	95,00	94,12	190	10	0	160
88,89	100,00	80,95	78,95	170	40	0	150
91,67	100,00	85,00	84,21	170	30	0	160

88,89	100,00	81,82	77,78	180	40	0	140
82,86	100,00	72,73	68,42	160	60	0	130
85,71	100,00	76,19	73,68	160	50	0	140
85,00	100,00	74,50	73,30	149	51	0	140
90,88	100,00	84,50	81,87	169	31	0	140
91,67	100,00	85,71	83,33	180	30	0	150
100,00	100,00	100,00	100,00	170	0	0	190
99,17	100,00	98,50	98,16	197	3	0	160
94,44	100,00	90,00	88,89	180	20	0	160
100,00	100,00	100,00	100,00	200	0	0	160
100,00	100,00	100,00	100,00	200	0	0	160
89,17	89,44	88,89	88,95	160	20	19	161
94,44	100,00	90,00	88,89	180	20	0	160
83,33	100,00	72,73	70,00	160	60	0	140
80,28	100,00	67,73	66,35	149	71	0	140
86,67	100,00	77,14	75,76	162	48	0	150
97,22	100,00	95,00	94,12	190	10	0	160
91,18	100,00	83,33	84,21	150	30	0	160
91,18	100,00	84,21	83,33	160	30	0	150
94,44	100,00	90,48	88,24	190	20	0	150
94,44	100,00	89,47	89,47	170	20	0	170
88,61	100,00	81,36	77,35	179	41	0	140
91,67	100,00	83,33	85,71	150	30	0	180
91,67	94,12	89,47	88,89	170	20	10	160
88,89	100,00	80,95	78,95	170	40	0	150
94,44	100,00	89,47	89,47	170	20	0	170
87,50	100,00	80,43	74,29	185	45	0	130
97,22	100,00	95,00	94,12	190	10	0	160
81,67	100,00	67,00	70,80	134	66	0	160
91,67	100,00	85,71	83,33	180	30	0	150
91,67	100,00	85,00	84,21	170	30	0	160
94,44	100,00	89,47	89,47	170	20	0	170
89,72	96,00	85,24	82,29	179	31	6	144
80,00	100,00	67,27	66,04	148	72	0	140
97,22	100,00	94,74	94,44	180	10	0	170
94,17	97,65	91,05	90,71	173	17	4	166
94,17	100,00	88,95	89,01	169	21	0	170
94,44	100,00	89,47	89,47	170	20	0	170
88,89	100,00	81,82	77,78	180	40	0	140
88,61	100,00	79,50	79,60	159	41	0	160
97,22	100,00	94,44	94,74	170	10	0	180

Figura 8. 1. Resultados Excel del análisis de forma conjunta de todas las cámaras.

Para realizar una lectura acerca de cuán fiables son los modelos, hemos obtenido la media y la desviación de cada una de las métricas de calidad.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	92,21	99,54	86,82	85,74
Desviación Típica	5,38	1,79	8,85	9,44

Figura 8. 2. Resultados Excel de la media y desviación típica de todas las cámaras.

A partir de estos datos, podemos apreciar que, en términos de sensibilidad, aludiendo a la explicación de este parámetro realizada en el capítulo 6, nuestra red proporciona unos datos muy buenos para el propósito que este proyecto se ha marcado como objetivo, ya que la detección de eventos de lluvia es el principal de ellos.

En cuanto a los parámetros restantes, los niveles bajan debido a que en muchas iteraciones los eventos detectados por la red como eventos de lluvia realmente están clasificados como eventos de no lluvia, lo que hace que los parámetros donde tienen en cuenta los FP no tengan los mismos resultados que en la sensibilidad.

Por otro lado, aunque los resultados de los parámetros de exactitud, especificidad y precisión no llegan al nivel de el parámetro sensibilidad, teniendo en cuenta el número de iteraciones que hemos realizado, podemos apreciar unos resultados buenos y que muestran robustez del funcionamiento de la red.

## 8.2 Modelo individual

En este apartado, vamos a exponer los resultados que hemos obtenido realizando un análisis cámara por cámara, es decir, realizando el mismo proceso que en el apartado anterior, pero con la diferencia de que en este caso analizaremos cada cámara por separado. Por lo tanto, en los siguientes subapartados vamos a mostrar los resultados de cada una de las cámaras en términos de métricas de calidad y la media y desviación típica que corresponde a cada una de ellas.

### *Cámara Hospital1-Barranoseco*

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	110	0	0	60
100,00	100,00	100,00	100,00	110	0	0	150
100,00	100,00	100,00	100,00	190	0	0	70
96,15	92,86	100,00	100,00	120	0	10	130
100,00	100,00	100,00	100,00	140	0	0	120

90,77	100,00	86,67	76,92	156	24	0	80
100,00	100,00	100,00	100,00	180	0	0	80
100,00	100,00	100,00	100,00	210	0	0	50
100,00	100,00	100,00	100,00	160	0	0	100
100,00	100,00	100,00	100,00	180	0	0	80
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	180	0	0	50
100,00	100,00	100,00	100,00	160	0	0	70
100,00	100,00	100,00	100,00	110	0	0	140
100,00	100,00	100,00	100,00	150	0	0	100
100,00	100,00	100,00	100,00	110	0	0	140
100,00	100,00	100,00	100,00	140	0	0	110
100,00	100,00	100,00	100,00	210	0	0	40
100,00	100,00	100,00	100,00	190	0	0	60
100,00	100,00	100,00	100,00	210	0	0	40
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	100	0	0	140
91,25	100,00	85,00	82,64	119	21	0	100
86,67	100,00	77,14	75,76	108	32	0	100
90,42	100,00	83,57	81,30	117	23	0	100
100,00	100,00	100,00	100,00	200	0	0	40
100,00	100,00	100,00	100,00	160	0	0	80
90,00	100,00	86,67	71,43	156	24	0	60
100,00	100,00	100,00	100,00	180	0	0	60
100,00	100,00	100,00	100,00	160	0	0	80
100,00	100,00	100,00	100,00	140	0	0	100
100,00	100,00	100,00	100,00	110	0	0	150
100,00	100,00	100,00	100,00	160	0	0	100
100,00	100,00	100,00	100,00	200	0	0	60
100,00	100,00	100,00	100,00	160	0	0	100
100,00	100,00	100,00	100,00	160	0	0	100
100,00	100,00	100,00	100,00	120	0	0	140
100,00	100,00	100,00	100,00	140	0	0	120
100,00	100,00	100,00	100,00	120	0	0	140
100,00	100,00	100,00	100,00	160	0	0	100
94,62	100,00	93,00	81,08	186	14	0	60
92,31	100,00	90,00	75,00	180	20	0	60
100,00	100,00	100,00	100,00	220	0	0	40
100,00	100,00	100,00	100,00	190	0	0	70
100,00	100,00	100,00	100,00	220	0	0	40
100,00	100,00	100,00	100,00	130	0	0	130
100,00	100,00	100,00	100,00	200	0	0	60
100,00	100,00	100,00	100,00	220	0	0	40

Figura 8. 3. Resultados Excel del análisis de la cámara Hospital1-Barrancoseco.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	98,64	99,86	98,04	96,88
Desviación Típica	3,33	1,01	5,21	7,93

Figura 8. 4. Resultados Excel de la media y desviación típica de la cámara Hospital1-Barranoseco

***Cámara Hospital2-Catedral***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	110	0	0	100
86,67	100,00	74,55	78,13	82	28	0	100
96,19	91,11	100,00	100,00	120	0	8	82
100,00	100,00	100,00	100,00	130	0	0	80
99,60	100,00	99,17	99,24	119	1	0	130
96,40	91,11	99,38	98,80	159	1	8	82
100,00	100,00	100,00	100,00	150	0	0	100
96,00	90,91	100,00	100,00	140	0	10	100
100,00	100,00	100,00	100,00	170	0	0	80
99,60	100,00	99,23	99,17	129	1	0	120
93,00	100,00	86,00	87,72	86	14	0	100
95,65	90,91	100,00	100,00	120	0	10	100
95,65	90,91	100,00	100,00	120	0	10	100
96,52	91,11	100,00	100,00	140	0	8	82
96,52	91,11	100,00	100,00	140	0	8	82
95,65	88,89	100,00	100,00	140	0	10	80
95,65	90,91	100,00	100,00	120	0	10	100
100,00	100,00	100,00	100,00	130	0	0	100
99,58	100,00	99,17	99,17	119	1	0	120
96,67	91,11	100,00	100,00	150	0	8	82
95,65	90,91	100,00	100,00	120	0	10	100
96,09	88,75	100,00	100,00	150	0	9	71
96,00	92,31	100,00	100,00	120	0	10	120
96,40	91,11	99,38	98,80	159	1	8	82
99,20	100,00	98,67	98,04	148	2	0	100
99,60	100,00	99,33	99,01	149	1	0	100
99,60	100,00	99,33	99,01	149	1	0	100
99,60	100,00	99,33	99,01	149	1	0	100
95,20	91,11	97,50	95,35	156	4	8	82
100,00	100,00	100,00	100,00	150	0	0	100
95,60	91,82	98,57	98,06	138	2	9	101
94,80	100,00	91,33	88,50	137	13	0	100
96,00	88,57	98,89	96,88	178	2	8	62

98,85	100,00	97,86	97,56	137	3	0	120
96,92	91,11	100,00	100,00	170	0	8	82
96,15	90,91	100,00	100,00	150	0	10	100
96,15	100,00	93,75	90,91	150	10	0	100
96,54	88,75	100,00	100,00	180	0	9	71
99,62	100,00	99,29	99,17	139	1	0	120
96,54	90,00	99,44	98,63	179	1	8	72
96,15	90,91	100,00	100,00	150	0	10	100
97,31	94,00	99,38	98,95	159	1	6	94
95,77	100,00	93,13	90,09	149	11	0	100
96,54	88,57	99,47	98,41	189	1	8	62
96,15	92,73	98,67	98,08	148	2	8	102
96,15	88,89	100,00	100,00	170	0	10	80
96,15	92,31	100,00	100,00	130	0	10	120
96,15	100,00	93,75	90,91	150	10	0	100
100,00	100,00	100,00	100,00	160	0	0	100
100,00	100,00	100,00	100,00	180	0	0	80

Figura 8. 5. Resultados Excel de la cámara Hospital2-Catedral.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	97,09	95,02	98,29	97,95
Desviación Típica	2,40	4,75	4,34	4,23

Figura 8. 6. Resultados Excel de la media y desviación típica de la cámara Hospital2-Catedral.

***Cámara Hospital3-Isleta***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	120	0	0	90
99,05	100,00	98,18	98,04	108	2	0	100
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	90	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	110	0	0	110
100,00	100,00	100,00	100,00	110	0	0	110
100,00	100,00	100,00	100,00	130	0	0	90
100,00	100,00	100,00	100,00	110	0	0	110
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	130	0	0	100

100,00	100,00	100,00	100,00	110	0	0	110
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	130	0	0	100
99,13	100,00	98,46	98,04	128	2	0	100
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	120	0	0	110

Figura 8. 7. Resultados Excel de la cámara Hospital3-Isleta.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,96	100,00	99,93	99,92
Desviación típica	0,18	0,00	0,33	0,39

Figura 8. 8. Resultados Excel de la media y desviación típica de la cámara Hospital3-Isleta.

*Cámara Hospital4-Escaleritas*

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	90	0	0	90
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	110	0	0	120
99,57	99,09	100,00	100,00	120	0	1	109
98,70	97,50	100,00	100,00	110	0	3	117
100,00	100,00	100,00	100,00	100	0	0	130
99,13	100,00	98,57	97,83	138	2	0	90
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	90	0	0	90
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	130	0	0	90
100,00	100,00	100,00	100,00	80	0	0	140
100,00	100,00	100,00	100,00	130	0	0	90
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	80	0	0	120
100,00	100,00	100,00	100,00	80	0	0	120
96,50	92,22	100,00	100,00	110	0	7	83
100,00	100,00	100,00	100,00	100	0	0	100
74,00	100,00	52,73	63,38	58	52	0	90
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	90	0	0	110
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	70	0	0	140
98,57	97,27	100,00	100,00	100	0	3	107
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	120	0	0	100
99,55	99,00	100,00	100,00	120	0	1	99

100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	110	0	0	110
100,00	100,00	100,00	100,00	120	0	0	100

Figura 8. 9. Resultados Excel de la cámara Hospital4-Escaleritas

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,32	99,70	99,03	99,22
Desviación Típica	3,70	1,21	6,68	5,18

Figura 8. 10. Resultados Excel de la media y desviación típica de la cámara Hospital4-Escaleritas

***Cámara Tafira1-Informática***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	110	0	0	80
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	130	0	0	80
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	80	0	0	80
100,00	100,00	100,00	100,00	100	0	0	80
100,00	100,00	100,00	100,00	100	0	0	80
100,00	100,00	100,00	100,00	110	0	0	70
100,00	100,00	100,00	100,00	90	0	0	90
98,89	100,00	97,78	97,83	88	2	0	90
100,00	100,00	100,00	100,00	80	0	0	100
100,00	100,00	100,00	100,00	100	0	0	80
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	100	0	0	90
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	110	0	0	90

99,50	100,00	99,23	98,59	129	1	0	70
100,00	100,00	100,00	100,00	130	0	0	70
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	100	0	0	100
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	110	0	0	90
100,00	100,00	100,00	100,00	120	0	0	80
100,00	100,00	100,00	100,00	100	0	0	100

Figura 8. 11. Resultados Excel de la cámara Tafira1-Informatica.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,97	100,00	99,94	99,93
Desviación Típica	0,17	0,00	0,33	0,36

Figura 8. 12. Resultados Excel de la media y desviación típica de la cámara Tafira1-Informatica.

***Cámara Tafira2-MontañaArucas***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	120	0	0	100
100,00	100,00	100,00	100,00	140	0	0	80
98,70	96,67	100,00	100,00	140	0	3	87
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	120	0	0	110

99,13	98,00	100,00	100,00	130	0	2	98
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	100	0	0	130
99,13	97,78	100,00	100,00	140	0	2	88
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	130	0	0	100
95,65	92,31	100,00	100,00	100	0	10	120
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	100	0	0	140
100,00	100,00	100,00	100,00	150	0	0	90
99,58	100,00	99,38	98,77	159	1	0	80
100,00	100,00	100,00	100,00	130	0	0	110
97,60	94,55	100,00	100,00	140	0	6	104
100,00	100,00	100,00	100,00	140	0	0	110
100,00	100,00	100,00	100,00	150	0	0	100
100,00	100,00	100,00	100,00	130	0	0	120
100,00	100,00	100,00	100,00	150	0	0	100
90,80	77,00	100,00	100,00	150	0	23	77
100,00	100,00	100,00	100,00	130	0	0	120
100,00	100,00	100,00	100,00	150	0	0	100
97,20	93,64	100,00	100,00	140	0	7	103
97,20	91,25	100,00	100,00	170	0	7	73
100,00	100,00	100,00	100,00	140	0	0	110
100,00	100,00	100,00	100,00	160	0	0	90
96,00	90,91	100,00	100,00	140	0	10	100

Figura 8. 13. Resultados Excel de la cámara Tafira2-MontañaArucas.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,42	98,64	99,99	99,98
Desviación Típica	1,61	3,90	0,09	0,17

Figura 8. 14. Resultados Excel de la media y desviación típica de la cámara Tafira2-MontañaArucas.

***Cámara Tafira3-FOSCAM***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	100	0	0	110
94,76	89,00	100,00	100,00	110	0	11	89
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	100	0	0	130
99,13	98,33	100,00	100,00	110	0	2	118
100,00	100,00	100,00	100,00	110	0	0	120
99,57	100,00	99,33	98,77	149	1	0	80
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	90	0	0	110
100,00	100,00	100,00	100,00	100	0	0	100
98,64	97,50	100,00	100,00	100	0	3	117
100,00	100,00	100,00	100,00	90	0	0	130
100,00	100,00	100,00	100,00	100	0	0	120
94,55	90,77	100,00	100,00	90	0	12	118
100,00	100,00	100,00	100,00	100	0	0	120
100,00	100,00	100,00	100,00	100	0	0	120
98,18	96,67	100,00	100,00	100	0	4	116
100,00	100,00	100,00	100,00	100	0	0	120
98,95	98,00	100,00	100,00	90	0	2	98
99,50	99,09	100,00	100,00	90	0	1	109
100,00	100,00	100,00	100,00	100	0	0	110
100,00	100,00	100,00	100,00	120	0	0	90
100,00	100,00	100,00	100,00	110	0	0	100
100,00	100,00	100,00	100,00	100	0	0	110
96,96	94,17	100,00	100,00	110	0	7	113
99,57	98,75	100,00	100,00	150	0	1	79
99,57	99,09	100,00	100,00	120	0	1	109
100,00	100,00	100,00	100,00	120	0	0	110
99,57	99,17	100,00	100,00	110	0	1	119
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	110	0	0	120

99,13	98,18	100,00	100,00	120	0	2	108
99,57	99,17	100,00	100,00	110	0	1	119
100,00	100,00	100,00	100,00	120	0	0	110
99,13	97,78	100,00	100,00	140	0	2	88
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	130	0	0	100
99,57	98,89	100,00	100,00	140	0	1	89
98,70	97,00	100,00	100,00	130	0	3	97
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	150	0	0	80
99,57	99,09	100,00	100,00	120	0	1	109
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	120	0	0	110

Figura 8. 15. Resultados Excel de la cámara Tafira3-FOSCAM.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,49	99,01	99,99	99,98
Desviación Típica	1,15	2,21	0,09	0,17

Figura 8. 16. Resultados Excel de la media y desviación típica de la cámara Tafira3-FOSCAM.

***Cámara Tafira4-FOSCAM***

Exactitud	Sensibilidad	Especificidad	Precisión	TN	FP	FN	TP
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	100	0	0	130
99,13	100,00	98,67	97,56	148	2	0	80
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	130	0	0	110
100,00	100,00	100,00	100,00	130	0	0	110
100,00	100,00	100,00	100,00	100	0	0	140
100,00	100,00	100,00	100,00	110	0	0	130
100,00	100,00	100,00	100,00	110	0	0	120
99,57	100,00	99,33	98,77	149	1	0	80
100,00	100,00	100,00	100,00	150	0	0	80
100,00	100,00	100,00	100,00	160	0	0	70
99,13	100,00	98,46	98,04	128	2	0	100

100,00	100,00	100,00	100,00	160	0	0	70
100,00	100,00	100,00	100,00	130	0	0	100
100,00	100,00	100,00	100,00	100	0	0	130
100,00	100,00	100,00	100,00	120	0	0	110
100,00	100,00	100,00	100,00	110	0	0	120
100,00	100,00	100,00	100,00	110	0	0	110
95,65	100,00	92,31	90,91	120	10	0	100
99,13	100,00	98,67	97,56	148	2	0	80
100,00	100,00	100,00	100,00	140	0	0	90
100,00	100,00	100,00	100,00	120	0	0	120
98,75	100,00	98,00	96,77	147	3	0	90
99,58	100,00	99,33	98,90	149	1	0	90
96,25	100,00	94,00	90,91	141	9	0	90
99,58	100,00	99,29	99,01	139	1	0	100
91,67	100,00	83,33	85,71	100	20	0	120
100,00	100,00	100,00	100,00	120	0	0	120
98,33	100,00	96,36	97,01	106	4	0	130
99,58	100,00	99,23	99,10	129	1	0	110
99,17	100,00	98,18	98,48	108	2	0	130
97,92	100,00	95,00	96,55	95	5	0	140
100,00	100,00	100,00	100,00	120	0	0	120
95,42	100,00	91,54	90,91	119	11	0	110
100,00	100,00	100,00	100,00	110	0	0	130
99,58	100,00	99,29	99,01	139	1	0	100
97,92	100,00	96,15	95,65	125	5	0	110
99,17	100,00	98,46	98,21	128	2	0	110
100,00	100,00	100,00	100,00	120	0	0	120
100,00	100,00	100,00	100,00	120	0	0	120
100,00	100,00	100,00	100,00	130	0	0	110
99,58	100,00	99,38	98,77	159	1	0	80
100,00	100,00	100,00	100,00	130	0	0	110
99,58	100,00	99,17	99,17	119	1	0	120
100,00	100,00	100,00	100,00	110	0	0	130
100,00	100,00	100,00	100,00	120	0	0	120
100,00	100,00	100,00	100,00	130	0	0	110

Figura 8. 17. Resultados Excel de la cámara Tafira4-FOSCAM.

	Exactitud	Sensibilidad	Especificidad	Precisión
Media	99,29	100,00	98,68	98,54
Desviación Típica	1,54	0,00	2,96	2,94

Figura 8. 18. Resultados Excel de la media y desviación típica de la cámara Tafira4-FOSCAM.

Debido a la homogeneidad de los resultados que hemos visualizado para cada una de las cámaras, la valoración la podemos realizar de forma conjunta. Por lo tanto, en este caso podemos apreciar que las medidas de calidad para cada cámara son muy buenas teniendo en cuenta todos los parámetros y las 50 iteraciones que realizamos para cada una de ellas, las cuales como habíamos comentado en el apartado anterior, proporcionan robustez a la credibilidad del funcionamiento de la red.

### ***8.3 Comparativa de Resultados Modelo General-Modelo Individual***

Si establecemos una comparativa entre ambos modelos, podemos apreciar una diferencia clara sobre todo en los parámetros de precisión, especificidad y exactitud, debido al valor de FP, que es mayor en el análisis del modelo general con respecto al modelo individual. La lectura que se puede realizar de esta diferencia está ligada a la cantidad de fotografías que analiza un modelo y otro, donde la diferencia es muy grande, analizando alrededor de 8 veces más en el modelo general, lo que afecta directamente a la red que se encuentra en condiciones más extremas, analizando además diferentes cámaras.



# CAPÍTULO 9: CONCLUSIONES

## *9.1 Introducción*

En este capítulo final del proyecto, vamos a explicar las conclusiones obtenidas a medida que hemos ido desarrollando los diferentes objetivos del proyecto. Por otro lado, queremos describir algunas mejoras y líneas de investigación futuras que se pueden llevar a cabo.

## *9.2 Conclusiones*

Una vez hemos finalizado las diferentes tareas previas al alcance de los objetivos establecidos en el inicio de este TFG, hemos llegado a las siguientes conclusiones:

- Las cámaras que hemos utilizado nos han aportado buenas resoluciones, que han permitido, por un lado, la correcta clasificación por nuestra parte de cualquier evento que queramos clasificar y la correcta lectura de la red.
- La base de datos que hemos creado, podemos decir que nos ha ayudado a mejorar considerablemente los resultados que hemos obtenido finalmente, debido a que su estructura sigue un equilibrio (balance) que permite conseguir un buen funcionamiento de la red.
- En lo que respecta a las técnicas de preprocesado de la imagen podemos decir que no hemos utilizado algunas técnicas como el balance de blancos que inicialmente habíamos planteado en los inicios del objetivo del proyecto, ya que en base a los resultados que obtuvimos, no apreciamos que fuera necesario añadirse al filtrado de Sobel para obtener mejores resultados, lo que hace que el funcionamiento del algoritmo se realice con una mayor eficiencia reduciendo la carga de trabajo en esta etapa. Por el mismo motivo no ha sido necesario aplicar técnicas de detección de movimiento de imágenes.

- El uso de la ROI ha hecho que podamos reducir notablemente el tamaño de las imágenes, y demostrando que el uso que hacemos funciona muy bien a la hora de ser evaluada por la red sin necesidad de trabajar con la imagen total.
- El método que hemos implementado para la detección y cuantificación de eventos de lluvia a partir de secuencias de vídeo en este TFG nos ha servido para alcanzar resultados que consideramos muy buenos teniendo en cuenta los parámetros de calidad que hemos extraído del funcionamiento de la red.

### ***9.3 Mejoras y líneas de investigación futuras***

En relación con las mejoras y futuras líneas de investigación que amplíen aspectos relacionados con el proyecto, podemos exponer las siguientes:

- Realizar nuevas medidas para el modelo general y comprobar dónde se podría mejorar los resultados que se han obtenido.
- Completar el sistema con un mapa de representación donde se vean los diferentes casos de eventos que están sucediendo.
- Investigar nuevas formas de preprocesado que aumenten la eficiencia y reduzcan los tiempos de ejecución obteniendo los mismos resultados.
- Ampliar la red de cámaras utilizadas.



# CAPÍTULO 10: BIBLIOGRAFÍA

- [1] R. A. Española, “Definición meteorología,” 2020. <https://dle.rae.es/meteorología> (accessed Dec. 12, 2020).
- [2] N. Sebe, I. Cohen, A. Garg, and T. S. Huang, *Machine learning in computer vision*. Springer, 2005.
- [3] S. Bronte, L. M. Bergasa, and P. F. Alcantarilla, “Fog detection system based on computer vision techniques,” *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 30–35, 2009, doi: 10.1109/ITSC.2009.5309842.
- [4] I. Sobel and G. Feldman, “A 3x3 isotropic gradient operator for image processing.,” *Hart, P. E. Duda R. O. Pattern Classif. Scene Anal.*, no. January 1973, pp. 271–272, 1973, [Online]. Available: <papers2://publication/uuid/F6C98D8E-0A99-40EF-A91C-0ECA53448D1F>.
- [5] G. Kumar and P. K. Bhatia, “A detailed review of feature extraction in image processing systems,” *Int. Conf. Adv. Comput. Commun. Technol. ACCT*, no. February, pp. 5–12, 2014, doi: 10.1109/ACCT.2014.74.
- [6] M. S. Nixon and A. S. Aguado, “Basic image processing operations,” *Featur. Extr. Image Process. Comput. Vis.*, pp. 83–136, 2012, doi: 10.1016/b978-0-12-396549-3.00003-3.
- [7] S. K. Kim, F. A. N. Liu, and S. S. Choi, “Multimedia applications for intelligent fusion computing,” *Multimed. Tools Appl.*, vol. 74, no. 10, pp. 3273–3276, 2015, doi: 10.1007/s11042-015-2459-y.
- [8] D. Kriesel, “A brief introduction to Neural Networks,” 2005. [http://www.dkriesel.com/en/science/neural\\_networks](http://www.dkriesel.com/en/science/neural_networks) (accessed Dec. 15, 2020).
- [9] Organización Meteorológica Mundial, *Atlas Internacional De Nubes - Manual De Observacion De Nubes Y Otros Meteoros*. 1993.
- [10] L. Magalhães, «Ciclo del agua», 2020. [En línea]. Disponible en: <https://www.todamateria.com/ciclo-del-agua/>. [Accedido: 17-dic-2020].
- [11] María Estela Raffino, «Ciclo del agua», 2020. [En línea]. Disponible en: <https://concepto.de/ciclo-del-agua/>. [Accedido: 17-dic-2020].
- [12] S. Núñez, “Tipos de precipitaciones,” 2020. <https://www.ecologiaverde.com/tipos-de-precipitaciones-3086.html> (accessed Nov. 29, 2020).

- [13] M. Padrón Hernández, «Climatología de Canarias». [En línea]. Disponible en: [https://www.gevic.net/info/contenidos/mostrar\\_contenidos.php?idcat=22&idcap=92&idcon=531](https://www.gevic.net/info/contenidos/mostrar_contenidos.php?idcat=22&idcap=92&idcon=531). [Accedido: 17-dic-2020].
- [14] “PLUVIÓMETRO.” <https://pluviometro.top> (Accedido: 02-dic-2020).
- [15] Francisco Javier Sánchez San Román, “Hidrología e Hidrogeología,” *Colomb. Pacífico*, vol. 1, pp. 120–134, 1993.
- [16] E. y C. S. A. S. interventoría, «¿Sabes en qué se diferencian un Pluviómetro y un Pluviógrafo?», 2020. [En línea]. Disponible en: <https://www.intesco.com.co/sabes-en-que-se-diferencian-un-pluviometro-y-un-pluviografo/>. [Accedido: 17-dic-2020].
- [17] N. Rosales Hernández, «Técnicas de aprendizaje máquina para detección y cuantificación de lluvia sobre imágenes de videovigilancia», Las Palmas de Gran Canaria, 2020.
- [18] «lo-mejor.com», 2020. [En línea]. Disponible en: <https://www.lo-mejor.com/hogar/comparativo-pluviometro-precio-opinion/>. [Accedido: 17-dic-2020].
- [19] Cultura y tecnología meteorológica, «Qué es una estación meteorológica», 2019. [En línea]. Disponible en: <https://estaciondemeteorologia.com/que-es-una-estacion-meteorologica/>. [Accedido: 17-dic-2020].
- [20] C. J. Pardo Herrera, «La visión por computador», *Histograma de gradientes orientados*, 2020.
- [21] M. R. B. Clarke, R. O. Duda, y P. E. Hart, «Pattern Classification and Scene Analysis», *J. R. Stat. Soc. Ser. A*, vol. 137, n.º 3, p. 442, 1974.
- [22] S. Bronte, L. M. Bergasa, y P. F. Alcantarilla, «Fog detection system based on computer vision techniques», *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 30-35, 2009.
- [23] J. Barrios, “Redes Neuronales Convolucionales,” 2020. <https://www.juanbarrios.com/redes-neurales-convolucionales/> (accessed Dec. 05, 2020).
- [24] Na8, “¿Cómo funcionan las Convolutional Neural Networks?,” 2018. <https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-networks-vision-por-ordenador/> (accessed Dec. 13, 2020).
- [25] C. Oropeza, “Capítulo 3: Redes Neuronales Recurrentes,” pp. 15–25, 2007, [Online]. Available:[http://catarina.udlap.mx/u\\_dl\\_a/tales/documentos/lem/oropeza\\_c\\_ca/](http://catarina.udlap.mx/u_dl_a/tales/documentos/lem/oropeza_c_ca/).
- [26] Missinglink.ai, “Deep Learning Long Short-Term Memory (LSTM) Networks.” <https://missinglink.ai/guides/neural-network-concepts/deep-learning-long-short-term-memory-lstm-networks-remember/>.

- [27] J. M. Casas Gonzalez, “Tuneando los hiperparámetros de una red neuronal LSTM para obtener un aprendizaje más eficiente,” 2020. <https://www.linkedin.com/pulse/tuneando-los-hiperparámetros-de-una-red-neuronal-lstm-casas-gonzalez?articleId=6679057971340701696#:~:text=Número de neuronas%3A es el,que tiene la capa LSTM.&text=Epoch%3A este es el número,de entrenamiento por la red.> (accessed Dec. 10, 2020).
- [28] J. Brownlee, «How to Configure the Learning Rate When Training Deep Learning Neural Networks», 2019. [En línea]. Disponible en: <https://machinelearningmastery.com/learning-rate-for-deep-learning-neural-networks>. [Accedido: 17-dic-2020].
- [29] J. Brownlee, «How to Avoid Exploding Gradients With Gradient Clipping», 2019. [En línea]. Disponible en: <https://machinelearningmastery.com/how-to-avoid-exploding-gradients-in-neural-networks-with-gradient-clipping/>. [Accedido: 17-dic-2020].
- [30] S. Fuente, «Técnicas de aprendizaje máquina para detección y cuantificación de lluvia mediante radioenlaces terrenos a frecuencia de gigahercios», Escuela de Ingeniería de Telecomunicación. Universidad de Las Palmas de Gran Canaria, 2020.
- [31] A. Manso Fernández, «Algoritmo para la identificación temprana de la sepsis a partir de datos clínicos», Escuela Politécnica Superior. Universidad de Alicante, 2020.



# **PARTE II: PRESUPUESTO**

En este apartado vamos a describir el presupuesto de los gastos que se han generado generados por el Trabajo de Fin de Grado. Para ser más precisos, se encuentra dividido en las siguientes partes:

- Tiempo empleado en la realización del trabajo y tarifado
- Amortización del material instrumental e informático
  - Amortización de los recursos hardware
  - Amortización del mobiliario
  - Amortización de los recursos software
- Redacción de la documentación

### ***P.1 Trabajo remunerado por tiempo empleado***

En este apartado se establecen los gastos correspondientes a la remuneración por hora del Graduado en Ingeniería. Dado que los honorarios pueden ser elegidos de forma voluntaria al no estar establecidos en ningún documento, se propone usar la siguiente ecuación:

$$R = 16,65 \times R_n + 20,10 \times R_e (\text{€})$$

donde:

16,65 es la remuneración por las horas trabajadas en horario normal

20,17 es la remuneración por las horas trabajadas fuera de horario laboral

R es la remuneración total por el tiempo dedicado

$R_n$  son las horas trabajadas en horario laboral

$R_e$  son las horas especiales trabajadas

El tiempo estimado de realización de este TFG es de 4 meses trabajados, desde septiembre hasta diciembre de 2020, trabajando aproximadamente 6 horas por día. Teniendo en cuenta alrededor de 20 días laborales al mes, el valor de horas normales es:

$$R_n = 4 \times 20 \times 6 = 480 \text{ (horas)}$$

El valor de horas especiales corresponde al trabajo realizado fuera del horario laboral, por lo que, contando los fines de semana empleados para adelantar trabajo, su valor asciende a:

$$Re = 15 \times 6 = 90 \text{ (€)}$$

Por tanto, el coste total de horas empleadas es:

$$R = 16,65 \times 480 + 20,10 \times 90 = 9.801 \text{ (€)}$$

## ***P.2 Amortización del material informático y equipamiento***

En este apartado vamos a tener en cuenta la amortización de materiales de tipo software, hardware y equipamiento, cuyo uso ha sido necesario para llevar a cabo la realización de este proyecto. Los datos que tomamos como referencia se han tomado de las tablas de coeficientes de amortización lineal de la Agencia Tributaria (AEAT), del cual se ha escogido el porcentaje o coeficiente lineal máximo para cada uno de los elementos que hemos comentado anteriormente.

### ***P.2.1 Amortización de los recursos Hardware***

En la siguiente tabla se definen todos los materiales hardware empleados a lo largo de los 4 meses de periodo de desarrollo del proyecto. Es por ello por lo que, para calcular el coste de amortización, hemos utilizado el porcentaje especificado en cada una de las tablas.

Elemento	Cantidad (uds)	Valor unidad	Coste total	Coef. Lineal max (%)	Coste de amortización
<i>Cámara GXV3674-FHD</i>	6	220 €	1.320 €	20	264,00 €
<i>FOSCAM FI9901EP</i>	2	170,00 €	340,00 €	20	68,00 €
<i>VAISALA WXT530</i>	1	1.000,00 €	1.000,00 €	20	200,00 €
<i>VAISALA RG13</i>	1	800,00 €	800,00 €	20	160,00 €
<i>Ordenador ASUS i7</i>	1	1.100,00 €	1.100,00 €	25	275,00 €
<i>monitor ACER 24"</i>	1	120,00 €	120,00 €	20	24,00 €
<i>monitor ACER 28"</i>	1	190,00 €	190,00 €	20	38,00 €
<i>ordenador ACER i7</i>	2	800,00 €	1.600,00 €	25	400
<b>TOTAL</b>					1.429,00 €

Tabla P. 1. Precios y costes de amortización de recursos hardware.

### *P.2.2 Amortización del mobiliario.*

En la siguiente tabla se definen todo el mobiliario empleados a lo largo de los 4 meses de periodo de desarrollo del proyecto.

Elemento	Cantidad (uds)	Valor unidad	Coste total	Coef. Lineal max (%)	Coste de amortización
<i>Sillas</i>	6	220 €	1.320 €	10	132,00 €
<i>Mesas</i>	2	170,00 €	340,00 €	10	34,00 €
<b>TOTAL</b>					166,00 €

Tabla P. 2. Precios y costes de amortización del mobiliario.

**P.2.3 Amortización de los recursos Software**

En la Tabla P.3 se muestran las herramientas software que se han usado para desarrollar este proyecto a lo largo de los 4 meses de proyecto.

Elemento	Valor unidad	Coef. Lineal max (%)	Coste de amortización
<i>Microsoft Office 365</i>	153,99 €	33	50,82 €
<i>MatLab 2020b</i>	2.500,00 €	33	825,00 €
<b>TOTAL</b>			<b>875,82 €</b>

Tabla P. 3. Precios y costes de amortización de recursos Software.

Una vez visualizado el coste de recursos software, podemos establecer el coste total de amortización del material informático y equipamiento:

Elemento	Coste
<i>Recursos Hardware</i>	1.429,00 €
<i>Mobiliario</i>	166,00 €
<i>Recursos Software</i>	875,82 €
<b>TOTAL</b>	<b>2.470,82 €</b>

Tabla P. 4. Coste total de material.

### ***P.3 Redacción del trabajo***

Para establecer el coste asociado a la redacción de la memoria del TFG, vamos a utilizar la siguiente ecuación:

$$R = 0,05 \times P$$

donde:

- R son los honorarios por la redacción del trabajo.
- P es el presupuesto.

El valor del presupuesto P lo hemos calculado sumando los costes de los apartados anteriores correspondientes al trabajo tarifado por tiempo empleado y a la amortización del material instrumental e informático, tanto hardware (H) como software (S) y mobiliario (M). Esta suma de los costes se muestra en la siguiente tabla:

$$P = R + H + S + M$$

<b>Concepto</b>	<b>Coste</b>
<i>Trabajo tarifado por tiempo empleado</i>	9.801,00 €
<i>Amortizacio hardware en de los recursos</i>	1.429,00 €
<i>Amortizacion de mobiliario</i>	875,82 €
<i>Amortizacion de los recursos software</i>	2.470,82 €
<b>TOTAL</b>	<b>14.576,64 €</b>

Tabla P. 5. Presupuesto con el trabajo realizado y el material utilizado.

Por lo tanto, obtenemos la siguiente ecuación:

$$R = 0,05 \times (14.576,64) = 728,83 \text{ €}.$$

**P.4 Aplicación de impuestos y coste total**

La realización del presente TFG está gravada por el Impuesto General Indirecto Canario, IGIC, en un 6,5 %. En la siguiente tabla se muestra el presupuesto final con los impuestos aplicados.

<b>Concepto</b>	<b>Coste</b>
<i>Trabajo tarifado por tiempo empleado</i>	9.801,00 €
<i>Amortizacion hardware en de los recursos</i>	1.429,00 €
<i>Amortizacion de mobiliario</i>	875,82 €
<i>Amortizacion de los recursos software</i>	2.470,82 €
<i>Realizacion del trabajo</i>	728,83 €
<b>Total (Sin IGIC)</b>	<b>15.305,47 €</b>
<b>IGIC (6,5 %)</b>	<b>994,86 €</b>
<b>TOTAL</b>	<b>16.300,33 €</b>

Tabla P. 6. Presupuesto final del Trabajo de Fin de Grado.

El presupuesto total del trabajo “Técnicas de procesamiento de imágenes de videovigilancia aplicadas a la detección de lluvia mediante aprendizaje máquina” es de dieciséis mil trescientos euros y treinta y tres céntimos.

Las Palmas de Gran Canaria, a 23 de diciembre de 2020.

Fdo.: Darío Javier Diaz Caballero



# **PARTE III: PLIEGO DE CONDICIONES**

## 1. Introducción

El presente Trabajo Fin de Grado comprende toda una serie de métodos y aplicaciones con técnicas de aprendizaje máquina para detección de lluvia mediante secuencias de vídeo. En el presente pliego de condiciones se trata tanto las condiciones legales, administrativas, derechos de explotación, restricciones de uso y garantías adicionales como las herramientas software como hardware necesarios para la elaboración del presente trabajo.

### C.1 Equipamiento Hardware

En este apartado vamos a describir las características más importantes del material hardware que hemos utilizado en este proyecto.

#### Modelos de cámaras:



La cámara modelo GXV364\_FHD tiene las siguientes características técnicas:

<b>COMPRESIÓN DE VÍDEO</b>	H.264, MJPEG
<b>RESOLUCIÓN DEL SENSOR DE IMAGEN</b>	1/3", 3.1 Megapixel Progressive Scan CMOS, 2048H x 1536V
<b>SENSIBILIDAD DEL SENSOR DE IMAGEN</b>	Modo día/noche. Bajo ruido y baja sensibilidad a la luz. Obturador: 1/10000 - 1/30 segundo
<b>DISTANCIA FOCAL</b>	2.8 ~ 12 mm
<b>APERTURA</b>	F1.4, DC-IRIS

<b>ANGULO DE CAMPO</b>	90° ~ 28° (Campo horizontal)
<b>FILTRO DE CORTE IR</b>	Si, mecánico
<b>MODO DÍA/NOCHE</b>	IR LED cubre hasta 25m
<b>ILUMINACIÓN MÍNIMA</b>	0.05 Lux, 0 lux con IR
<b>RECEPTIVIDAD</b>	1.9V/lux-segundo (550nm)
<b>VÍDEO MÁXIMO ADMITIDO</b>	2048x1536 (15 imágenes)
<b>RESOLUCIÓN Y VELOCIDAD DE FOTOGRAMAS</b>	1920x1080 (30 imágenes)
<b>VELOCIDAD BIT</b>	32 Kbps ~ 8 Mbps velocidad múltiple para vista previa y grabación
<b>ENTRADA DE AUDIO</b>	Line-In, 1500 ohms, 0.1Vrms ~ 0.707Vrms, 3.5mm
<b>SALIDA DE AUDIO</b>	Line-Out, 600 ohms, 0.707Vrms, 3.5mm
<b>COMPRESIÓN DE AUDIO</b>	G.711u/a, AAC
<b>ANALÍTICA EMPOTRADA</b>	Detección de movimiento (hasta 16 áreas objetivo)
<b>PRE-/POST-ALARMA DE GRABACIÓN</b>	Si, 3MB
<b>WDR (WIDE DYNAMIC RANGE)</b>	Si (100dB)
<b>INSTANTÁNEAS</b>	Activado por eventos, enviar por correo electrónico / FTP
<b>PROTOCOLO DE RED</b>	TCP/UDP/IP, RTP/RTCP, RTSP, DHCP, DDNS, HTTP, HTTPS, SMTP, FTP, NTP
<b>SOPORTE SIP/VOIP</b>	Si
<b>FOTOGRAFÍA DE LAPSO DE TIEMPO</b>	Si
<b>MÁSCARA DE PRIVATICIDAD</b>	Si, 4 zonas
<b>POWER OVER ETHERNET (POE)</b>	IEEE 802.3af, Clase 0
<b>CONEXIÓN DE CABLES EXTERNOS</b>	Red: RJ45, 10M/100M autodetección 3.5mm Line-In 3.5mm Line-Out Power Input
<b>DIMENSIONES</b>	255mm (L) x 104mm (W) x 187mm (H)
<b>PESO</b>	1.10kg
<b>TEMPERATURA/HUMEDAD</b>	En funcionamiento: -20°C ~ +50°C (-4°F ~ 122°F), 10–90% RH (no–condensación) En almacenamiento: -30°C ~ +60°C (-22°F ~ 140°F)
<b>ADAPTADOR DE ALIMENTACIÓN</b>	Salida: 12VDC/1A; Entrada: 100–240VAC, 50–60Hz
<b>CAJA EXTERNA O CARCASA</b>	Carcasa de metal resistente a la intemperie IP66
<b>CONFORMIDAD</b>	FCC Parte 15, Subparte B Clase B; EN 55022 Clase B, EN 61000-3-2, EN 61000-3-3, EN 55024, EN 60950-1; C-tick AS/NZS CISPR 22, IP66

Tabla C. 1. Características técnicas del modelo GXV364\_FHD.



La cámara modelo FOSCAM FI9901EP tiene las siguientes características técnicas, ilustrada en la tabla:

<b>SENSOR DE IMAGEN</b>	Sensor	High Definition Color 1/3" CMOS Sensor
	Resolución	2560 x 1440 Pixels (4.0 Megapixels), 2304 x 1296 Pixels (3.0 Megapixels). 2X Magic Zoom and 6X Digital Zoom
	Iluminación	0 Lux mínimo (con iluminación infrarroja incorporada)
	Controles	Control de brillo, contraste y frecuencia de luz. Automáticos y manuales
<b>LENTE</b>	Lente	Cristal; Lentes IR-infrarrojas de visión nocturna. f: 2.8 mm, 78° visión diagonal
<b>VÍDEO</b>	Compresión vídeo	H.264
	Stream	Doble stream
	Imágenes/seg.	30 fps máx. (ajustable a valores inferiores)
	Resolución	2560 x 1440 Pixels (4.0 Megapixels), 2304 x 1296 Pixels (3.0 Megapixels). 2X Magic Zoom and 6X Digital Zoom
	Volteo imagen	Vertical / Horizontal
	Frecuencia luz	50Hz, 60Hz o Exterior
	Modo infrarrojo	Automático y Manual
	Ajustes vídeo	Brillo, Contraste
<b>SONIDO</b>	Entrada/Salida	Conectores jack estándares 3.5 mm para entrada/salida de audio. Compresión PCM/G.726
<b>COMUNICACIÓN</b>	Red Ethernet	10/100 Mbps RJ-45 con PoE IEEE802.3af
	Protocolos	HTTP, P2P (acceso vía Internet sin necesidad de abrir puertos), FTP, TCP/IP, UDP, SMTP, DHCP, PPPoE, UPnP, GPRS
<b>ALMACENAMIENTO</b>	Tarjeta microSD	Ranura para tarjeta microSD

<b>SISTEMAS COMPATIBLES</b>	Sistema operativo	Windows XP, Vista, 7, 8, 10; MacOS, iOS, Android
	Navegador	IE, Firefox, Chrome, Safari
<b>DATOS FÍSICOS</b>	Luz infrarroja	IR LEDs, Alcance nocturno hasta 20 m
	Dimensiones	En mm.: 98 (La) x 65 (An) x 62 (Al)
	Orientación	180° horizontal / 180° vertical
	Peso	500 gr (accesorios incluidos)
<b>ALIMENTACIÓN</b>	Alimentación	Adaptador DC 12V/1.0A (incluido). El cable mide 1,5 m.
	PoE	Alimentable eléctricamente por PoE (cable ethernet). Estándar IEEE802.3af
	Consumo	<5 W
<b>ENTORNO</b>	Temperatura	-20° ~ 55°C (operativa) -20°C ~ 60°C(almacenamiento)
	Humedad	10% ~ 80% sin condensación (óptima operativa) 0% ~ 90% sin condensación (almacenamiento)
<b>CERTIFICACIÓN Y NORMATIVA</b>	CE, RoHs, FCC, IP66 (estanqueidad en modelos exterior)	

<b>EQUIPAMIENTO DE CÁMARAS</b>	
<b>Herraje de instalación</b>	
<b>Mástil de sujeción</b>	
<b>Cableado</b>	
<b>Armario de exterior con ventilación formado por:</b>	Un Switch 8 puertos con POE UBNT-ES-8-150W
	Un PSU / Rectificador 48-56V
	Un Cuadro eléctrico con magnetotérmico 2P 16A, diferencial 2P 25A 30mA y monitor de tensión con contacto NNNC
	Con su correspondiente herraje de instalación, mástil de sujeción y cableado

<b>EQUIPAMIENTO DE RECEPCIÓN DE LOS DATOS EN EL LABORATORIO</b>	
Router Mikrotik RB2011	
Sistema de alimentación ininterrumpida (SAI) de 700VA marca Salicru SPS.900.ONE	

Tabla C. 2. Características técnicas del modelo FOSCAM FI9901EP.

**Modelos de pluviómetros:**

<p><b>PLUVIÓMETRO MODELO VAISALA WXT530</b></p>	
<p><b>ÁREA DE CAPTACIÓN</b></p>	<p>60cm<sup>2</sup>.</p>
<p><b>PRECIPITACIÓN</b></p>	<p>Por acumulación después del último reinicio automático o manual.</p>
<p><b>RESOLUCIÓN</b></p>	<p>0.01mm.</p>
<p><b>PRECISIÓN PARA LA ACUMULACIÓN DIARIA.</b></p>	<p>Mejor al 5%.</p>
<p><b>DURACIÓN</b></p>	<p>Incrementos de 10 segundos desde que se detecta la precipitación.</p>
<p><b>INTENSIDAD</b></p>	<p>La ejecución tiene un promedio de 1 minuto para pasos de 10 segundos.</p>
<p><b>RANGO DE LA INTENSIDAD</b></p>	<p>0-200mm.</p>
<p><b>RESOLUCIÓN DE LA INTENSIDAD</b></p>	<p>0.1mm/h.</p>
<p><b>GRANIZO</b></p>	<p>Cantidad de golpes acumulados contra la superficie de captación.</p>

Tabla C. 3. Características del pluviómetro modelo VAISALA WXT530.

<p><b>VAISALA RG13</b></p>	
<p><b>PRECISIÓN</b></p>	<p>Mejor al 2%.</p>
<p><b>DIÁMETRO DE APERTURA</b></p>	<p>225mm.</p>
<p><b>ÁREA DE APERTURA</b></p>	<p>400cm<sup>2</sup>.</p>
<p><b>CAPACIDAD DE PRECIPITACIÓN</b></p>	<p>Ilimitada</p>
<p><b>RESOLUCIÓN</b></p>	<p>0.2mm.</p>
<p><b>DURACIÓN</b></p>	<p>&lt;100ms</p>

Tabla C. 4. Características del pluviómetro modelo VAISALA RG13.

**Modelos de ordenadores:**

<p><b>ORDENADOR PORTÁTIL ASUS</b></p>	
<p><b>PROCESADOR</b></p>	<p>Intel ® Core ™ i7-8565U CPU @ 1.80GHz</p>
<p><b>RAM INSTALADA</b></p>	<p>16 GB</p>
<p><b>TIPO DE SISTEMA</b></p>	<p>Sistema operativo de 64 bits</p>
<p><b>SISTEMA OPERATIVO</b></p>	<p>Microsoft Windows 10 Home</p>

Tabla C. 5. Características técnicas del ordenador ASUS.

<p><b>ORDENADOR SOBREMESA ACER</b></p>	
<p><b>PROCESADOR</b></p>	<p>10th Generation Intel® Core™ i5-10400</p>
<p><b>RAM INSTALADA</b></p>	<p>8 GB DDR4</p>
<p><b>TIPO DE SISTEMA</b></p>	<p>Sistema operativo de 64 bits</p>
<p><b>SISTEMA OPERATIVO</b></p>	<p>Microsoft Windows 10 Home</p>

Tabla C. 6. Características técnicas del ordenador ACER.

## ***C.2 Herramientas software***

- **Microsoft office Word:** Aplicación de la suite ofimática Microsoft Office utilizada para la redacción del documento.
- **Microsoft office Excel:** Aplicación de la suite ofimática Microsoft Office utilizada para la elaboración de las tablas presentes en el TFG.
- **Microsoft office Power Point:** Aplicación de la suite ofimática Microsoft Office utilizada para la elaboración de la presentación del presente TFG.
- **MatLab version 2020b:** 64 bits, para el desarrollo de la totalidad de los algoritmos implementados en este TFG.
- **Base de datos:** Específica para el presente TFG en el marco del Proyecto VIMETRI-MAC (Navarro Mesa & Ravelo García, 2017-2019). Tanto los datos meteorológicos, como los datos de videovigilancia, han sido obtenidos a partir de una plataforma web gestionada por el propio proyecto VIMETRI-MAC. Los datos expuestos en este TFG solo se podrán usar previa autorización expresa de los responsables del Proyecto VIMETRI-MAC y, en su caso, se hará con la debida referencia a la propiedad y autoría.

## ***C.3 Condiciones legales y administrativas***

A continuación, se exponen los aspectos de tipo legal y administrativo que habrán de ser tenidos en cuenta para los futuros usuarios. Estas condiciones establecen las obligaciones, derechos y deberes que los autores adquieren con los usuarios del sistema implementado en este trabajo de fin de grado, y a su vez de los usuarios con los autores.

### ***Derechos de explotación y restricciones de uso***

La Universidad de Las Palmas de Gran Canaria es quien ostenta los derechos de explotación y cualquier usuario debe de estar de acuerdo en obligarse por los términos y condiciones establecidas en este Pliego de Condiciones, aceptando todos sus términos y estipulaciones; de igual manera se deberá de cumplir lo establecido en el “*Reglamento general de los trabajos de fin de grado y de fin de máster de las titulaciones oficiales de la Universidad de Las Palmas de Gran Canaria*”, aprobado por acuerdo de Consejo de Gobierno de la ULPGC de 28 de noviembre de 2019 (BOULPGC 5 diciembre 2019), que en su capítulo VI reglamenta los derechos de propiedad intelectual, de explotación industrial y protección de datos personales.

El uso de programas o partes de estos, y base de datos o de una copia en ordenador personal de los mismos, será bajo la autorización expresa del autor, el o los tutores del trabajo fin de grado y el director de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

El usuario no podrá realizar ingeniería inversa, decompilación o desensamblado de los programas o partes de estos. El usuario podrá transferir los programas y bases de datos a un tercero, siempre que no tenga copias de estos, incluyendo posibles actualizaciones o retener material escrito adicional que acompañe a los programas y la base de datos.

### ***Garantías y consideraciones adicionales***

El autor y los directores del TFG garantizan que los programas o partes de estos, y la base de datos funcionarán correctamente en el momento de la correcta instalación. También se garantiza que el soporte en el cual está grabado el programa no contendrá defectos en el momento de la adquisición de este.

Con la única excepción de lo expresamente expuesto en el párrafo anterior, los programas y bases de datos han sido creados sin garantías de ningún tipo. No se asegura, garantiza, o realiza ninguna declaración respecto al uso o los resultados derivados de la utilización de los programas o la base de datos. Tampoco se garantiza que la operación

de los programas sea ininterrumpida o sin errores.

La confiabilidad de operación del programa puede ser afectada por factores adversos a los que se denominan fallas del sistema. En estos se incluyen fluctuaciones en el sistema de alimentación eléctrico, errores en el funcionamiento del hardware del ordenador personal, sistema operativo o entorno del ordenador personal o entorno de desarrollo y ejecución usado para realizar la aplicación, errores de instalación, problemas de compatibilidad de software y hardware, fallas o funcionamientos incorrectos de equipos de control, fallas por uso, o errores por parte del usuario o autor de la aplicación.

Cualquier aplicación donde una falla de sistema pueda crear un riesgo de daño a la propiedad o personas, no puede ser imputada al programa. Para evitar daños, el usuario deberá tomar razonablemente, todas las precauciones necesarias.

Las garantías y consideraciones aquí expresadas se regirán por las leyes del estado español. El usuario acepta la jurisdicción exclusiva de los tribunales de este país con relación a cualquier disputa que pudiera derivarse de los derechos y garantías estipuladas en este documento.

En ningún caso serán el autor, ni los tutores del TFG, ni la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria responsables de los perjuicios directos, indirectos, incidentales, probatorios o de los consiguientes, gastos, lucro cesante, pérdida de ahorros, interrupción de negocios, pérdida de información comercial o de negocio, o cualquier otra pérdida que resulte del uso o de la incapacidad de usar los programas o la base de datos. El usuario conoce y acepta esta asignación de riesgo, así como el resto de las garantías, derechos, deberes y restricciones. Se rechaza cualquier otra garantía, derecho, deber o restricción que no haya sido citada directamente en el Pliego de Condiciones.

