



UNED

RECONOCIMIENTO Y DETECCIÓN **DE INCENDIOS POR MEDIO DE** **TÉCNICAS DE VISIÓN ARTIFICIAL**

MÁSTER UNIVERSITARIO EN INGENIERÍA DE SISTEMAS Y CONTROL

TRABAJO FIN DE MÁSTER

CURSO 2017 / 2018

Alumno: Guillermo Tomás Cabanillas Canelo

Director: Gonzalo Pajares Martinsanz

Septiembre 2018

MÁSTER EN INGENIERÍA DE SISTEMAS Y CONTROL

PROYECTO DE TRABAJO FIN DE MÁSTER

**RECONOCIMIENTO Y DETECCIÓN DE INCENDIOS
POR MEDIO DE TÉCNICAS DE VISIÓN ARTIFICIAL**

PROYECTO ESPECÍFICO PROPUESTO POR EL ALUMNO

ALUMNO: GUILLERMO TOMÁS CABANILLAS CANELO

DIRECTOR: GONZALO PAJARES MARTINSANZ



UNED

AUTORIZACIÓN DE DIFUSIÓN.

Autorizamos a la Universidad Complutense y a la UNED a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a sus autores, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firmado:

Alumno: Guillermo Tomás Cabanillas Canelo

Fecha: 7 septiembre de 2018

ÍNDICE

RESUMEN	VI
PALABRAS CLAVE	VI
ABSTRACT	VII
KEYWORDS	VII
LISTA DE FIGURAS	VIII
LISTA DE TABLAS	X
SIGLAS, ABREVIATURAS Y ACRÓNIMOS.	XI
AGRADECIMIENTOS	XII
CAPÍTULO 1. INTRODUCCIÓN.	1
CAPÍTULO 2. CONCEPTOS BÁSICOS DE LA TEORÍA DEL FUEGO.	4
CAPÍTULO 3. FUNDAMENTOS TEÓRICOS EN LA DETECCIÓN DE IMÁGENES.	7
3.1. Principios de visión artificial aplicados a la detección de imágenes.	7
3.2. Imágenes térmicas. Método de umbralización de Otsu.	9
3.3. Reconocimiento de patrones. Métodos de aprendizaje y clasificación.	11
3.3.1. Fuzzy K-means.	12
3.3.2. Clasificador Bayesiano.	14
3.3.3. Algoritmo generalizado de Lloyd.	16
3.3.4. Self-Organizing Maps (SOM).	17
3.4. Identificación mediante análisis de movimiento.	19
3.4.1. Método de Lucas-Kanade.	19
CAPÍTULO 4. APLICACIÓN DE LOS MÉTODOS PROPUESTOS. RESULTADOS OBTENIDOS.	22
4.1. Planteamiento práctico.	22
4.2. Método de umbralización de Otsu.	24
4.3. Reconocimiento de patrones.	38
4.3.1. Fuzzy K-means.	41
4.3.2. Clasificador Bayesiano.	52
4.3.3. Algoritmo generalizado de Lloyd.	58
4.3.4. Self-Organizing Maps (SOM).	64
4.3.5. Conclusiones de los métodos de reconocimiento.	69
4.4. Análisis de movimiento.	72
4.4.1. Método de Lucas-Kanade.	73
4.4.2. Mejoras y alternativas en la detección de movimiento.	79

CAPÍTULO 5. CONCLUSIONES Y LÍNEAS FUTURAS.	85
BIBLIOGRAFÍA.	88
ANEXOS.	90
ANEXO A. Equipos utilizados.	90
ANEXO B. Muestras en los métodos de aprendizaje.	92
ANEXO C. Tablas de validación de las muestras.	97
ANEXO D. Tablas comparativas de los centros de las clases.	101

RESUMEN

Este Trabajo Fin de Máster pertenece al campo de la Visión Artificial o Visión por Computador, y dentro de este campo más específicamente se centra en el análisis de imágenes con el fin de aplicarlo en el reconocimiento de patrones y formas. El elemento objeto de estudio es el fuego con sus diferentes manifestaciones, y lo que se pretende es la identificación de los incendios en su fase temprana, con el fin de minimizar las consecuencias negativas de éstos.

El procesamiento y análisis de imágenes ha experimentado un considerable progreso y evolución en los últimos tiempos, encontrando aplicación en campos y materias de lo más diverso: medicina, biología, cartografía, astronomía, robótica, entre otros, ya que continuamente están surgiendo nuevas utilidades y métodos.

Por otro lado, es de sobra conocido el poder destructivo del fuego, y como tal, la lucha contra incendios es un campo también en continuo avance y desarrollo, en lo que respecta a la prevención, detección y extinción de incendios. Los sistemas automáticos contra incendios aportan mejoras importantes frente a la intervención humana, ya que son más seguros, fiables, precisos y capaces de operar continuamente, además de permitir el control de procesos peligrosos o inviables de supervisar de forma directa como los nucleares, químicos o biológicos.

De este modo, el objetivo final que se pretende con este trabajo es evaluar la posibilidad de aplicar las técnicas de visión artificial a la detección automática de incendios, comprobando las ventajas e inconvenientes de cada uno de los métodos, según el entorno y circunstancias consideradas.

En primer lugar se considera la extracción de regiones por la umbralización de histogramas de intensidad según el método de Otsu. A continuación se realiza otra alternativa con el reconocimiento de patrones, según los métodos de aprendizaje y clasificación, estudiando en concreto los métodos Fuzzy K-means, el clasificador bayesiano, el algoritmo generalizado de Lloyd y los mapas auto organizados. Por último se comprueba la detección por medio del análisis de movimiento, para lo que se aplica el método de Lucas-Kanade.

PALABRAS CLAVE

Análisis de movimiento, aprendizaje y clasificación, clasificador bayesiano, detección, fuego, Fuzzy K-means, imágenes térmicas, incendios, Lloyd, Lucas-Kanade, Otsu, reconocimiento de patrones, Self-Organizing Maps, umbralización, visión por computador.

ABSTRACT

This Project belongs to the field of artificial vision or computer vision, and within this field more specifically it focuses on image analysis in order to apply it in recognizing patterns and shapes. The item under study is the fire with its different manifestations, and the aim is to identify fires at an early stage in order to minimize their negative consequences.

Processing and image analysis has experienced an important progress and evolution lately, finding application in fields and subjects as diverse as: medicine, biology, cartography, astronomy, robotics, and others, as new uses and methods are continuously arising.

On the other hand, the destructive power of fire is well known, and so, firefighting is also a field in continuous progress and development, with regard to the prevention, detection and firefighting. Automatic fire suppression systems provide significant improvements over human performance, as they are more secure, reliable, accurate and able to operate continuously, allowing for the control of dangerous or unfeasible to monitor processes directly by human intervention, such as nuclear, chemical or biological.

Thus, the ultimate goal intended with this work is to evaluate the possibility of applying artificial vision techniques to automatic fire detection, checking the advantages and drawbacks of each of the methods, depending on the environment and considered circumstances.

First of all, the regions extraction by thresholding intensity histograms according to the Otsu method is considered. Then, another alternative is performed with pattern recognition according to the learning and classifying methods, specifically applying Fuzzy K-means, the Bayesian classifier, the generalized Lloyd algorithm and Self-Organizing Maps. Finally, the detection is checked by means of motion analysis, for which the Lucas-Kanade method is applied.

KEYWORDS

Motion analysis, learning and classification, Bayesian classifier, detection, fire, Fuzzy K-means, thermal imaging, burning, Lloyd, Lucas-Kanade, Otsu, pattern recognition, Self-Organizing Maps, thresholding, computer vision.

LISTA DE FIGURAS

Figura 1: Triángulo del fuego.	4
Figura 2: Representación cartesiana del modelo RGB.	8
Figura 3: Histograma de intensidad con un valor umbral T.	9
Figura 4: Histograma de intensidad con dos valores umbrales T_1 y T_2	10
Figura 5: Clasificación según dos atributos diferentes x_1 y x_2	11
Figura 6: Definición de símbolos para la ecuación de restricción del flujo óptico 19	19
Figura 7: Imágenes consecutivas de la misma secuencia, y flujo óptico correspondiente. 21	21
Figura 8: Escenario de la fuga de gas.	25
Figura 9: Imágenes del escenario de gas tomadas con la cámara térmica y sin combustión. 25	25
Figura 10: Histograma con la distribución de intensidades para la imagen FG CT 00. 26	26
Figura 11: Imágenes obtenidas por el método de multiumbralización de Otsu, con 4 umbrales. 27	27
Figura 12: Conducto de gas, antes y después de circular el fluido por él. 27	27
Figura 13: Imágenes de gas en combustión con cámara térmica y al aplicar el método de Otsu, $n=4$ 28	28
Figura 14: Histograma con la distribución de intensidades para la imagen FG CT 03. 28	28
Figura 15: Imágenes con 7 umbrales (8 regiones) y 9 umbrales (10 regiones). 29	29
Figura 16: Escenario de fuego líquido previo y en combustión. 30	30
Figura 17: Imágenes térmicas de la combustión líquida. 31	31
Figura 18: Histograma con la distribución de intensidades para la imagen FL CT 00. 31	31
Figura 19: Histograma con la distribución de intensidades para la imagen FL CT 02. 32	32
Figura 20: Imágenes con el método de umbralización de Otsu, para 4 umbrales y 5 regiones. 32	32
Figura 21: Imagen térmica FL CT 01 y su histograma de intensidad correspondiente. 33	33
Figura 22: Imagen térmica etiquetada con 4, 7 y 9 umbrales respectivamente. 34	34
Figura 23: Escenario de fuego sólido, inicial y en combustión. 35	35
Figura 24: Imágenes de fuego sólido. Sin combustión (FS CT 00) y con combustión. 35	35
Figura 25: Histograma de la imagen FS CT 00. Intervalos [0,255] y [20,255] respectivamente. 36	36
Figura 26: Histogramas de intensidades para las imágenes FS CT 01 y FS CT 04, respectivamente. 36	36
Figura 27: Resultado de aplicar el método de Otsu ($n = 4$) a imágenes FS CT 00, FS CT 01 y FS CT 04. 37	37
Figura 28: Imágenes de las regiones identificadas según el método de Otsu con $n = 7$ y $n = 9$ 38	38
Figura 29: Imágenes de fuego de gas para el aprendizaje en el reconocimiento de patrones. 40	40
Figura 30: Imágenes de fuego de líquido para el aprendizaje en el reconocimiento de patrones. 40	40
Figura 31: Imágenes de fuego de sólido para el aprendizaje en el reconocimiento de patrones. 41	41
Figura 32: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego de gas. 42	42
Figura 33: Proyección bidimensional de los puntos y centros de las clases. Fuego de gas. 43	43
Figura 34: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means. . 44	44
Figura 35: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means. . 45	45
Figura 36: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means. . 45	45
Figura 37: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego líquido. 46	46
Figura 38: Proyección bidimensional de los puntos y centros de las clases. Fuego líquido. 47	47
Figura 39:: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Fuzzy K-means. 48	48
Figura 40: Imagen del escenario previo y su representación de la clasificación según el algoritmo Fuzzy K-means. 48	48
Figura 41: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Fuzzy K-means. 49	49
Figura 42: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego sólido. 49	49
Figura 43: Proyección bidimensional de los puntos y centros de las clases. Fuego de gas. 50	50

Figura 44: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Fuzzy K-means. ...	51
Figura 45: Imagen del escenario y su representación de la clasificación según el algoritmo Fuzzy K-means.	51
Figura 46: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Fuzzy K-means. ...	52
Figura 47: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.	53
Figura 48: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.	53
Figura 49: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.	54
Figura 50: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Bayesiano. ...	55
Figura 51: Imagen del escenario de líquido y su representación de la clasificación según el algoritmo Bayesiano.	55
Figura 52: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Bayesiano. ...	55
Figura 53: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo Bayesiano.	56
Figura 54: Imagen del escenario de fuego sólido y su representación según el algoritmo Bayesiano.	57
Figura 55: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Bayesiano.	57
Figura 56: Imagen de fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.	59
Figura 57: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.	60
Figura 58: Imagen de fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.	60
Figura 59: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo AGL.	61
Figura 60: Imagen del escenario de fuego líquido y su representación de la clasificación según el algoritmo AGL.	61
Figura 61: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo AGL.	62
Figura 62: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo AGL.	62
Figura 63: Imagen de escenario de fuego sólido y su representación de la clasificación según el algoritmo AGL.	63
Figura 64: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo AGL.	63
Figura 65: Imagen de fuego de gas y su representación de la clasificación según el algoritmo SOM.	65
Figura 66: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo SOM.	65
Figura 67: Imagen de fuego de gas y su representación de la clasificación según el algoritmo SOM.	65
Figura 68: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo SOM.	66
Figura 69: Imagen del escenario de fuego líquido y su representación de la clasificación según el algoritmo SOM.	67
Figura 70: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo SOM.	67
Figura 71: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo SOM.	68
Figura 72: Imagen de escenario de fuego sólido y su representación de la clasificación según el algoritmo SOM.	68
Figura 73: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo SOM.	69
Figura 74: Comparación entre los diferentes métodos aplicados sobre la imagen FL CV 04.	71
Figura 75: Secuencia de imágenes de fuego de gas con CV en escala de grises.	73
Figura 76: Resultado de aplicar el método LK, a las imágenes FG CV 01 y FG CV 02. Imagen LK FG CV 12.	74
Figura 77: Secuencia de imágenes de fuego de gas con CT.	74
Figura 78: Resultado de aplicar el método LK, a las imágenes FG CT 03 y FG CT 04. Imagen LK FG CT 34.	75
Figura 79: Secuencia de imágenes de fuego de líquido con CV en escala de grises.	75
Figura 80 Resultado de aplicar el método LK, a las imágenes FL CV 02 y FL CV 03. Imagen LK FL CV 23.	76
Figura 81: Secuencia de imágenes de fuego de líquido con CT.	76
Figura 82: Resultado de aplicar el método LK, a las imágenes FL CT 02 y FL CT 04. Imagen LK FL CT 24.	77
Figura 83: Secuencia de imágenes de fuego de sólido con CV en escala de grises.	77
Figura 84: Resultado de aplicar el método LK, a las imágenes FS CV 04 y FS CV 05. Imagen LK FS CV 45.	78
Figura 85: Secuencia de imágenes de fuego de sólido con CT.	78
Figura 86: Resultado de aplicar el método LK, a las imágenes FS CT 01 y FS CT 04. Imagen LK FS CT 14.	79
Figura 87: Secuencia de imágenes de fuego de sólido con CV en escala de grises.	79
Figura 88: Resultado de aplicar el método LK, a las imágenes FS2 CV 04 y FS2 CV 05. Imagen LK FS2 CV 45.	80

Figura 89: Imágenes de fuego líquido.....	81
Figura 90: Imágenes de fuego líquido.....	81
Figura 91: Imágenes de fuego líquido.....	82
Figura 92: Imagen LK FL 23 r, resultante de aplicar sobre imágenes clasificadas y reducidas.....	82
Figura 93: Imagen Dif FL CV 23, resultante de aplicar el método de diferencias.....	83
Figura 94: Imagen con la clasificación de la imagen Dif FL CV 23, según los métodos de Fuzzy, Bayes, AGL y SOM.....	84

LISTA DE TABLAS

Tabla 1: Resumen resultado de los métodos de clasificación según el tipo de fuego.....	70
Tabla 2: Características técnicas de la cámara térmica.....	90
Tabla 3: Características técnicas de la cámara digital compacta operando en el espectro visible.....	90
Tabla 4: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de gas.	92
Tabla 5: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de líquido....	93
Tabla 6: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de sólido.	95
Tabla 7: Comparativa de los coeficientes de validación para el algoritmo Fuzzy K-means.	97
Tabla 8: Comparativa de los valores de la divergencia entre clases, para los distintos tipos de fuego.	98
Tabla 9: Comparativa de los valores del coseno entre vectores media, para los distintos tipos de fuego.	98
Tabla 10: Comparativa de los valores de la DJM entre clases, para los distintos tipos de fuego.	99
Tabla 11: Centros obtenidos para las clases según el método de aprendizaje aplicado y el tipo de fuego.	101

SIGLAS, ABREVIATURAS Y ACRÓNIMOS.

AGL. Algoritmo Generalizado de Lloyd.

Bayes. Algoritmo clasificador bayesiano.

CE. Coeficiente de Entropía.

CP. Coeficiente de Partición.

CT. Cámara Térmica.

CV. Cámara digital operando en el espectro Visible.

Div. Divergencia.

DJM. Distancia Jeffries – Matusita.

FG. Fuego de Gas.

FL. Fuego de Líquido.

FS. Fuego de Sólido.

Fuzzy. Algoritmo Fuzzy K-means.

LK. Método de Lucas – Kanade.

MOT. Método de umbralización de Otsu.

RGB. Red, Green, Blue.

SOM. Self-Organizing Maps (Mapas Autoorganizativos).

TFM. Trabajo Fin de Máster.

UNE. Una Norma Española (Asociación Española de Normalización).

AGRADECIMIENTOS

En primer lugar me gustaría agradecer la labor del director de este Trabajo Fin de Máster, Gonzalo Pajares Martinsanz, sin sus comentarios y orientaciones nunca hubiera sido posible su conclusión. Es ejemplar su disposición y atención permanente, adaptándose a mis circunstancias y contestando a mis correos a horas intempestivas. Por supuesto, gracias también a todo el personal docente que me ha guiado y acompañado durante mis estudios de Máster.

Gracias a mis padres, Antonio y Julita, por enseñarme a aprender; a mi mujer, Estela, por apoyarme en este camino; y a mis hijos, Valentina y Pablo, por motivarme a seguir superándome cada día.

Por último, agradecer a mis compañeros de trabajo, de estudios y amigos, en especial a Luis Miguel Trujillo por su ayuda con los escenarios de fuego y a Rubén Peña por sus comentarios e ideas.

“Vision is the art of seeing things invisible.”

(“La visión es el arte de ver lo que es invisible”)

Jonathan Swift (1667 – 1745)

CAPÍTULO 1. INTRODUCCIÓN.

El fuego es un elemento fundamental en el desarrollo de la humanidad, ya que supuso un avance evolutivo para la especie muy importante al permitir cocinar y conservar por más tiempo los alimentos, o fabricar útiles y herramientas más complejos con los que mejorar sus actividades diarias. Por supuesto, también es conocido desde tiempos inmemoriales el poder devastador y la capacidad destructiva que posee este elemento, contra la cual el ser humano ha realizado ingentes esfuerzos con el fin de mejorar en la extinción, detección y prevención de toda clase de incendios.

La detección de incendios es un factor esencial en el control y extinción de los mismos, ya que la evolución de un fuego, en lo referente a su intensidad o energía que se libera, es una curva exponencial en la cual a medida que pasa el tiempo es mucho más difícil el control del suceso. Suponiendo un tiempo de respuesta fijo desde el descubrimiento hasta el comienzo de la extinción, ya sea bien por medios humanos o sea por medio de sistemas automáticos, es por lo tanto el tiempo de detección el que determina que un pequeño fuego se quede en un conato sin importancia o llegue a ser un incendio destructivo total.

Así, el campo de la detección de incendios automática presenta una amplia variedad de medios y dispositivos con los que dar respuesta a la innumerable cantidad de situaciones que nos podemos encontrar: incendios domésticos, industriales o comerciales; incendios de interior o exterior; incendios de sólidos, líquidos o gases; de productos químicos, explosivos, radiactivos, etc.

Los continuos avances de la tecnología, la automatización y los nuevos materiales, permiten hoy en día la existencia de sofisticados dispositivos capaces de realizar su labor de manera muy eficiente en los entornos más exigentes.

Desde este punto de partida, se pretende con este trabajo, comprobar la aplicabilidad y uso de las modernas técnicas de visión artificial en la detección de incendios, como apoyo y mejora de los sistemas ya existentes antes mencionados.

De este modo, se realiza un análisis a partir de imágenes obtenidas con cámaras digitales y cámaras térmicas de varias clases de fuego, concretando dicho análisis en los siguientes métodos como los más apropiados a priori para las circunstancias propuestas:

- Para imágenes obtenidas con cámara térmica, a partir de su representación en escala de grises, se puede comprobar cómo las zonas de mayor temperatura aparecen representadas en los niveles más claros, mientras que a su vez, los niveles más oscuros se corresponden con las zonas de menor temperatura. Con este método, sería posible identificar en una imagen de este tipo aquellos lugares en los que existiera algún proceso de combustión y la consiguiente emisión de energía en forma de radiación. Una técnica apropiada en estas circunstancias sería la extracción de regiones por el método de

multiumbralización de Otsu (Otsu, 1979). Trabajos en esta línea ya están presentes (Díaz, 2017), aunque no aplicados tan específicamente a la detección de incendios.

- Para imágenes obtenidas con cámara digital operando en el espectro visible, se realiza su estudio a través del análisis de la imagen en sus canales de color RGB. En este caso lo que se pretende es la diferenciación de color. A partir de imágenes previas en las que se hace una clasificación por regiones de características y patrones similares, se intenta posteriormente en nuevas imágenes, detectar aquellas zonas en las que existiría una textura común correspondiente al color del fuego. Estos métodos de reconocimiento de patrones constan por lo tanto de dos fases, una de aprendizaje y otra de clasificación. De entre los métodos y algoritmos clasificadores se han seleccionado (Pajares y Cruz, 2007; Duda y col, 2001): Fuzzy K-means, Bayes, Lloyd y Self-Organizing Maps (SOM).
- Para las imágenes térmicas y RGB, se estudia finalmente, la posibilidad de detección del fuego mediante análisis del movimiento. Se realiza la comparación entre dos imágenes consecutivas, en las que lógicamente existirán oscilaciones del humo y la llama, y por lo tanto se puedan aplicar algoritmos de detección de movimiento. El método elegido en este caso es el algoritmo de Lucas-Kanade (Lucas y Kanade, 1981).

En esta memoria se describe en primer lugar la base teórica de los métodos, para luego posteriormente aplicarlos a las diferentes imágenes obtenidas con las cámaras digitales, en el espectro visible y térmico. Finalmente se realiza un análisis y evaluación de los resultados obtenidos, en los que se extraen las conclusiones oportunas y se indican posibles mejoras y líneas de actuación futuras.

La primera parte comienza con una breve descripción de la teoría del fuego, con el fin de conocer y describir aquellos aspectos fundamentales que puedan resultar necesarios para el estudio de este trabajo. Seguidamente se justifica la importancia de los métodos de visión artificial y el análisis por ordenador aplicados a la detección de imágenes, para a continuación describir detalladamente cada uno de los métodos elegidos en nuestro caso: método de multiumbralización de Otsu, Reconocimiento de patrones por aprendizaje y clasificación (Fuzzy K-means, Bayes, Lloyd y Self-Organizing Maps) e identificación de movimiento por el método de Lucas-Kanade.

Para la parte práctica se han implementado los algoritmos de los diversos métodos en el entorno de trabajo Matlab (2017), y se han aplicado sobre las distintas imágenes capturadas, obteniendo las consiguientes imágenes y representaciones. Se ha realizado un número elevado de muestras, pero se presenta sólo una parte de aquellas en las que se consiguen unos criterios mínimos de calidad aceptables, para poder ser estudiados y analizados con rigor científico.

OBJETIVOS.

Los objetivos generales que se pretenden alcanzar con este proyecto son:

1. Examinar e interpretar imágenes térmicas y RGB, con el fin de extraer la información relevante, útil y significativa que pueda ser necesaria para las diferentes aplicaciones.
2. Aplicar los métodos estudiados de análisis de imágenes en la detección de incendios, para los diferentes tipos de fuego.
3. Analizar los resultados obtenidos y evaluar los métodos utilizados, comprobando la validez y aplicabilidad de los mismos.
4. Proponer posibles mejoras y concretar soluciones viables en un posible sistema completo, capaz de detectar procesos de combustión de forma fiable, segura, inmediata y práctica.

Como objetivos específicos a conseguir, destacan los siguientes:

1. Evaluar las condiciones de utilización del método de multiumbralización de Otsu.
2. Aplicar técnicas de aprendizaje automático y justificar su uso con los algoritmos Fuzzy K-means, Clasificador Bayesiano, Generalizado de Lloyd y Self-Organizing Maps.
3. Interpretar la validez de los métodos de detección de movimiento, como el algoritmo de Lucas-Kanade, en la detección de fuegos.

En base a los anteriores objetivos, el trabajo que se propone realiza un estudio detallado tanto de métodos de clasificación como de detección del movimiento y su aplicación a la detección del fuego, siendo la adaptación de estos métodos junto con su combinación la contribución fundamental del trabajo realizado en este ámbito de aplicación concreto.

ORGANIZACIÓN DE LA MEMORIA.

Este trabajo se estructura en cinco capítulos.

1. En el capítulo uno se introduce el tema y objetivos del estudio.
2. El capítulo dos se introducen los conceptos básicos sobre el fuego con fines de detección mediante análisis de imágenes visibles y térmicas.
3. En el capítulo tres se introduce el marco teórico basado en métodos de clasificación y análisis de movimiento.
4. En el capítulo cuatro se analizan los resultados obtenidos desde el punto de vista de los métodos de clasificación y movimiento por separado y de forma conjunta.
5. Finalmente, el capítulo cinco concluye con las apreciaciones más relevantes y se proporcionan indicios para la continuidad de la investigación en el futuro.

CAPÍTULO 2. CONCEPTOS BÁSICOS DE LA TEORÍA DEL FUEGO.

La norma UNE 13943 (2012) define el fuego como una combustión caracterizada por la emisión de calor, humo y llamas. Dicha norma también define la combustión como una reacción química exotérmica de oxidación en la que se combina un elemento que arde (combustible) con otro elemento que produce la combustión (comburente). La velocidad del proceso es la que determina si se trata de una simple oxidación o una violenta explosión.

Es por lo tanto una reacción química de transferencia de electrones, en la que se desprende energía (exotérmica) y se producen otros nuevos elementos resultantes de dicha reacción química. La manifestación física de estos elementos son la luz (radiación), humo y gases asociados.

Es necesario, según lo mencionado anteriormente, la presencia simultánea de tres elementos para que se produzca la combustión: combustible, comburente y energía de activación (Hitado, 2015). Del mismo modo que un triángulo para ser triángulo necesita de tres lados, el fuego necesita de estos tres elementos para ser fuego, por ello se suele representar el mismo como el Triángulo del Fuego, figura 1. La extinción y análogamente la prevención de incendios, consiste en la eliminación de uno de los lados para su consecución.

Hoy en día se suele representar más precisamente por medio de un tetraedro, con la misma idea, pero teniendo en cuenta la necesaria presencia de la reacción en cadena, factor que determina que la energía liberada sea capaz de producir nuevas reacciones, pasando a ser un proceso exotérmico (libera energía) en lugar de endotérmico (absorbe energía).



Figura 1: Triángulo del fuego.

El comburente que suele ser el oxígeno, es el elemento que se combina con el combustible y actúa como oxidante, permite la combustión para concentraciones superiores al 10 – 12 % y está presente en la atmósfera de forma natural normalmente en torno al 20'9%. El oxígeno es el principal comburente, aunque no se debe ignorar la presencia de otros agentes oxidantes en forma de productos químicos, ya que actúan como acelerantes de la reacción y aumentan su peligrosidad.

La energía de activación o foco de ignición, es cualquier fuente de energía tanto eléctrica, como mecánica por fricciones o rozamientos, chispas y materiales incandescentes, materiales a alta temperatura, de origen químico, entre otros, capaces de provocar la ruptura de los enlaces en los reactivos e iniciar la reacción de oxidación, dando lugar a la combustión. Sin ella los elementos permanecerían estables.

El último elemento, el combustible, es el elemento reductor de la reacción, el que se oxida y por lo tanto cede electrones. Las innumerables sustancias que pueden actuar como combustible dependen de las condiciones ambientales, y se diferencian según su poder calorífico (dependiendo de su energía interna y enlaces moleculares), el estado físico en el que se encuentran y el grado de disgregación de la materia¹.

Esta característica de los combustibles nos permite hacer una clasificación de los tipos de fuego que nos podemos encontrar UNE-EN 2 (1994). Así tendríamos:

- Fuegos clase A: Combustibles sólidos con alto punto de fusión. Forman brasa.
- Fuegos clase B: Combustibles líquidos o sólidos con bajo punto de fusión.
- Fuegos clase C: Combustibles en fase gaseosa.
- Fuegos clase D: Metales químicamente activos. De muy difícil extinción.

Aunque existe alguna clase adicional a estas anteriores, para nuestro objetivo es suficiente con las tres primeras (A, B y C) por ser las más comunes y habituales.

La combustión como reacción química es un proceso que se produce siempre en fase gaseosa, por ser éste el estado de la materia en el que se produce la oxidación o intercambio de electrones entre los reactivos. De ahí la emisión con llamas en las combustiones que se producen íntegramente en fase gaseosa. Los cuerpos sólidos y los líquidos deben alcanzar su temperatura de inflamación, que es aquella a la que se emiten suficientes vapores susceptibles de inflamarse e iniciar la combustión, en un proceso que se conoce como pirólisis. Los sólidos pueden arder en forma de brasas, como combustiones latentes e incandescentes, sin emitir llamas como tal.

Con respecto a los mecanismos de transmisión del calor y la energía presentes en todo proceso en el que existe una diferencia de temperatura, se clasifican de tres maneras: por conducción, radiación y convección.

¹ Depende de la superficie de contacto con el calor. Mayor superficie para una misma cantidad de masa arde más fácilmente, motivo por el que arde mejor por ejemplo 1 Kg de serrín que 1 Kg de madera del mismo tipo.

- La conducción se produce principalmente en los cuerpos sólidos por contacto molecular directo debido a las vibraciones energéticas de las partículas. La agitación térmica se transmite por el material de una partícula a otra, permaneciendo en su posición original.
- La radiación es una forma de energía que se desplaza a través del espacio o los materiales en forma de ondas electromagnéticas visibles como la luz, o no, como los rayos infrarrojos, rayos X, etc.
- La convección es el movimiento molecular que se produce en un medio fluido circulante (principalmente gases o líquidos), por el cual las masas calientes, menos densas que las frías, pesan menos y realizan un movimiento ascendente, mientras que las masas frías realizan un movimiento descendente.

Los productos resultantes en la reacción de combustión serán: llamas o incandescencia que se manifiestan como radiación; humos formados por vapor de agua y restos aerosoles de la combustión incompleta de los materiales; y gases de todo tipo que pueden ser visibles o invisibles, dependiendo de los reactivos que se tengan en origen, pero que se encontrarán a temperaturas muy elevadas ($600^{\circ}\text{C} - 1200^{\circ}\text{C}$).

Estos productos, o más específicamente sus fenómenos físicos asociados, serán el efecto encargado de activar el sistema de detección con el que pretendemos proteger y prevenir el incendio en una determinada área. De esta forma encontraremos detectores de humo, que pueden ser iónicos u ópticos por efecto fotoeléctrico, térmicos, detectores de radiación, de gases, dependiendo del producto de la combustión a detectar. La variedad es muy amplia, con el fin de atender a la diversidad de situaciones, ambientes, combustibles o riesgos que queramos proteger.

En nuestro caso, para la detección por técnicas de visión artificial, aplicaremos sobre las tres clases de fuego A, B y C, la observación de la radiación emitida y capturada por cámaras digitales en imágenes RGB y la radiación emitida por la combustión en sí misma, materiales circundantes o gases presentes, capturada por las cámaras térmicas.

CAPÍTULO 3. FUNDAMENTOS TEÓRICOS EN LA DETECCIÓN DE IMÁGENES.

3.1. Principios de visión artificial aplicados a la detección de imágenes.

El campo de la visión artificial por computador ha tenido un desarrollo muy importante en los últimos años. Las técnicas y métodos de procesamiento de imágenes se han multiplicado cada vez más, tomando aplicación en campos y materias de lo más diverso como: astronomía, medicina, ingeniería, agricultura o robótica. Uno de los objetivos que se quieren alcanzar en este ámbito es la percepción de forma automática del entorno, por parte de los sistemas que interactúan con él, con el fin de interpretar y extraer la información necesaria para realizar las tareas encomendadas.

Las imágenes se estructuran en forma de matriz de puntos denominados píxeles, en la cual el número de los mismos nos proporcionará el nivel de precisión y detalle que podemos conseguir, y el valor que almacena cada uno de ellos nos representa la intensidad. En las cámaras térmicas la información se almacena como una matriz en dos dimensiones de valores, una imagen digital monocromática, donde cada número representa la intensidad y ésta a su vez es una cuantificación de la recepción de los fotones emitidos por los cuerpos debidos a su temperatura. Para imágenes obtenidas con cámaras operando en el espectro visible, el proceso es similar, pero en esta ocasión el color se representa según el modelo RGB, donde cada uno de los puntos almacena ahora tres valores, los correspondientes a cada uno de los canales en los que se puede descomponer la imagen: R (rojo), G (verde) y B (azul).

La escena tridimensional es capturada de este modo por las cámaras para producir imágenes monocromáticas o en color. El análisis de dichas imágenes y su representación numérica en base a algún atributo como la intensidad o el color mencionado, permite por ejemplo segmentarlas para obtener algunas características de interés como los bordes, cambios significativos de intensidad, o regiones, zonas con magnitudes similares. Esta segmentación se basa por lo tanto en el estudio de discontinuidades con el fin de localizar los bordes y en el estudio de similitudes de las propiedades de los puntos para regiones. El proceso de descripción posterior permite conocer los atributos de las características y tratarlas según sea necesario para su uso en las aplicaciones. Es decir, consiste en reconocer las diferentes estructuras de la imagen para su identificación de forma unívoca.

Para la detección de regiones algunas de las técnicas basadas en el hecho de la similitud son:

- Binarización basada en el uso de umbrales.
- Crecimiento de regiones mediante la adición de píxeles.
- División de regiones.
- Similitud de textura, color o nivel de gris.

La comparación de imágenes consecutivas en forma de secuencia a lo largo del tiempo, también puede ser un método válido para detectar la presencia de determinados objetos en movimiento. La observación de los cambios de intensidad luminosa en una escena y la evolución del flujo óptico, como se realiza en el método de Lucas – Kanade (Lucas y Kanade, 1981), son un ejemplo concreto de ello.

El uso del color se justifica en el procesamiento de imágenes ya que es un importante descriptor de las mismas y en cierto modo se intenta emular el funcionamiento del ojo humano como elemento captador del entorno. Los colores de la realidad se forman como combinación de los tres colores primarios rojo (R), verde (G) y azul (B). A dichos colores primarios se les asignó² los siguientes valores de longitud de onda en el espectro electromagnético: azul = 435,8 nm, verde = 546,1 nm y rojo = 700 nm. Estos colores se pueden mezclar para producir los colores secundarios de la luz visible: magenta (rojo y azul), cian (verde y azul) y amarillo (rojo y verde). La mezcla de los tres colores primarios o secundarios en proporciones iguales produce color blanco.

Además otras características importantes que se utilizan para la distinción de colores son el brillo, asociado al concepto de intensidad; el matiz, referente a la longitud de onda dominante en la combinación de ellas, o como el color percibido por el observador; y la saturación, como la pureza relativa o cantidad de luz blanca mezclada con un matiz (el grado de saturación es inversamente proporcional a la cantidad de luz blanca añadida).

Para representar un modelo de color de forma analítica se puede especificar un sistema de coordenadas cartesianas en 3 dimensiones, figura 2, donde cada punto dentro de dicho sistema corresponderá a un color en concreto.

Concretando en el modelo RGB mencionado, se puede asignar un eje cartesiano a cada una de las componentes espectrales primarias, formando un cubo con una distribución de los valores rojo, verde y azul en tres de sus vértices, los colores secundarios cian, magenta y amarillo en otros tres vértices opuestos, el negro se le asignaría el vértice origen y el blanco en el vértice de la diagonal más alejado del origen. De esta forma, la diagonal que une los vértices negro (origen) y blanco contendría la escala de grises, y el resto de colores de la gama serían puntos




Figura 2: Representación cartesiana del modelo RGB.

² CIE (Comisión Internationale de l'Eclairage) en 1931.

dentro del cubo, definidos por sus correspondientes vectores desde el origen.

3.2. Imágenes térmicas. Método de umbralización de Otsu.

Los píxeles de una imagen se caracterizan por el valor de su intensidad luminosa. La representación gráfica en forma de diagrama de barras de estos valores, se conoce con el nombre de histograma. Muestra en uno de sus ejes, el de ordenadas, la frecuencia de aparición de los valores, y en el otro eje, el de abscisas, los valores de intensidad, por ejemplo desde 0 (negro) hasta 255 (blanco). De esta manera, se puede conseguir un análisis de la luminosidad de la imagen, o incluso de las regiones presentes en ella.

A partir del histograma de niveles de gris de una captura, se puede comprobar que los píxeles de una determinada región presentarán una distribución de intensidad similar. Esto nos permite seleccionar las regiones de interés, y si fuera el caso, establecer aquellos valores que actuarían como umbral y separar las regiones con características similares. También es aplicable a imágenes en color, con las diferencias oportunas.

La detección de objetos por medio de umbrales en los histogramas, es una herramienta valiosa para el tratamiento de imágenes en sistemas de visión industrial donde se requiera gran procesamiento de datos.

En la figura 3 se puede comprobar el histograma de una imagen correspondiente a objetos claros sobre fondo oscuro, donde se agrupan las intensidades $I(x,y)$ según sus tonos dominantes. A partir de un determinado nivel T , se pueden separar los dos niveles de intensidad, de forma que para valores $I(x,y) > T$, tendremos las regiones pertenecientes a los objetos y para $I(x,y) < T$, serán las regiones pertenecientes al entorno, de fondo más oscuro.

Esta técnica permite la binarización de una imagen, otorgando simplemente dos valores de intensidad a los píxeles, dependiendo de su posición a un lado u otro del valor umbral.

De forma más general, para un histograma se pueden elegir varios valores umbrales, seleccionando de esta forma varios objetos según sus intensidades. Los métodos de umbralización multinivel, figura 4, a pesar de ello, presentan menos fiabilidad que los simples, ya que se encuentra la dificultad de elegir adecuadamente los valores que permitan distinguir efectivamente las regiones de interés.

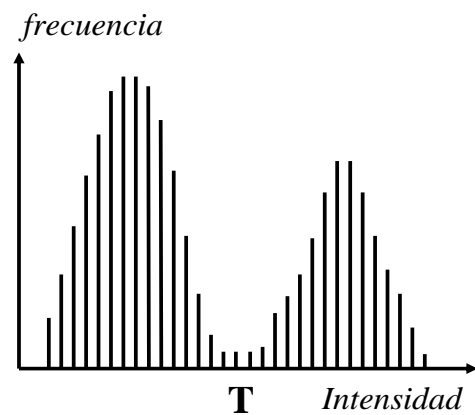


Figura 3: Histograma de intensidad con un valor umbral T .




Figura 4: Histograma de intensidad con dos valores umbrales T_1 y T_2 .

Se creará una imagen binaria $g(x,y)$ definiendo,

$$g(x,y) = \begin{cases} 0 & \text{si } f(x,y) > T \\ 1 & \text{si } f(x,y) \leq T \end{cases} \quad (3.1)$$

Como en el caso del histograma bimodal se supone que la imagen posee un histograma formado por la suma de dos densidades de probabilidad gaussianas donde cada gaussiana se aproxima a uno de los lóbulos. Esto hace suponer que a medida que las gaussianas se asemejan al histograma real, las desviaciones estándar deben disminuir y como consecuencia de ello se debe elegir aquél umbral que minimice la suma de las varianzas de los dos lóbulos del histograma³.

Según el método de Otsu a aplicar, dada una imagen con L niveles de intensidad y asumiendo que el umbral buscado es T , las probabilidades acumuladas hasta T y desde T hasta L resultan ser,

$$w_1(t) = \sum_{z=1}^T P(z) \quad \text{y} \quad w_2(t) = \sum_{z=T+1}^L P(z) \quad (3.2)$$

A continuación se obtienen las medias y varianzas asociadas,

$$\mu_1(t) = \sum_{z=1}^T zP(z) \quad \text{y} \quad \mu_2(t) = \sum_{z=T+1}^L zP(z) \quad (3.3)$$

$$\sigma_1^2(t) = \sum_{z=1}^T (z - \mu_1(t))^2 \frac{P(z)}{w_1(t)} \quad \text{y} \quad \sigma_2^2(t) = \sum_{z=T+1}^L (z - \mu_2(t))^2 \frac{P(z)}{w_2(t)} \quad (3.4)$$

Finalmente se obtiene la varianza ponderada

$$\sigma_w^2(t) = w_1(t)\sigma_1^2(t) + w_2(t)\sigma_2^2(t) \quad (3.5)$$

³ Otsu (1979).

Se elige el umbral T correspondiente al nivel de intensidad que proporcione la mínima varianza ponderada, obtenida según la ecuación (3.5).

3.3. Reconocimiento de patrones. Métodos de aprendizaje y clasificación.

El reconocimiento de patrones es la disciplina científica cuyo objetivo es la clasificación de objetos en un cierto número de categorías o clases. Dependiendo de la aplicación esos objetos pueden ser imágenes, formas de ondas de señales o cualquier tipo de medidas que necesitan ser clasificadas. Nos referiremos a esos objetos de forma genérica utilizando el término de patrones. La Visión por Computador es un área en la cual el reconocimiento de patrones tiene una gran importancia.

Podemos clasificar patrones, objetos o caracteres según sus similitudes, ya que todos aquellos que sean de una misma clase (representen lo mismo) presentarán una distribución de probabilidad alrededor de un elemento característico de esa clase. Analizando características cuantitativas se puede hacer una representación gráfica.




Figura 5: Clasificación según dos atributos diferentes x_1 y x_2 .

En la figura 5 se clasifican objetos en dos clases diferentes C_M y C_P , los objetos son representados por cuadrados y por círculos, en función de dos características cuantitativas x_1 y x_2 . En nuestro caso emplearemos los valores de los canales R, G y B de 0 a 255, cuya combinación determina un color exacto y con ello podremos identificar objetos según sus tonalidades.

Es importante tener acceso a una serie de imágenes con las que generar una base de datos de valores importante, y en la que se realizará el proceso de aprendizaje y entrenamiento, para posteriormente poder hacer el proceso de clasificación, de la forma lo más fiable posible con las nuevas imágenes que se capturen y en las que se encuentren los objetos a identificar.

El enfoque se centra en la descripción de métodos, para aprender a partir de los datos desde un punto de vista estadístico. Por tanto, distinguimos dos estados en la operación de un sistema de aprendizaje: (1) aprendizaje/estimación a partir de las muestras de entrenamiento y (2) operación/predicción, cuando las predicciones se hacen para muestras futuras o de prueba. Esta descripción supone que tanto los datos de entrenamiento como los datos de prueba corresponden a la misma distribución.

Una muestra de entrada $x = \{x_1, x_2, \dots, x_d\}$ necesita ser clasificada en uno y sólo uno de los c grupos o clases c_1, c_2, \dots, c_c . La existencia de los grupos se conoce a priori. El vector de entrada x representa atributos de alguna característica de la imagen, en nuestro caso valores de un vector RGB desde 0 a 255, y además se desconoce la clase a la que pertenece. La clasificación se refiere a la relación entre la etiqueta de pertenencia a la clase etiquetada como y y el vector de características x .

La clasificación representa de este modo, un caso especial de problema de aprendizaje. El aprendizaje resulta ser por tanto, el problema de encontrar la función del clasificador, que minimiza la probabilidad de clasificación errónea utilizando sólo los datos de entrenamiento.

3.3.1. Fuzzy K-means.

Los vectores contenidos en un grupo R_i son similares entre sí y menos similares a los vectores de otro grupo. Una definición es la proporcionada en términos de los *conjuntos difusos*. Un agrupamiento difuso de X en m grupos se caracteriza por m funciones u_j donde

$$u_j : X \rightarrow [0,1], \quad j = 1, \dots, m \quad (3.6)$$

y

$$\sum_{j=1}^m u_j(x_i) = 1, \quad i = 1, 2, \dots, n, \quad 0 < \sum_{j=1}^n u_j(x_i) < n, \quad j = 1, 2, \dots, m \quad (3.7)$$

Las u_j son las denominadas *funciones miembro*. El significado de estas funciones miembro es que cada vector x pertenece a más de un grupo simultáneamente hasta un cierto grado, que se cuantifica por el correspondiente valor u_j en el intervalo $[0,1]$. Los valores próximos a la unidad muestran un alto grado de pertenencia en el grupo correspondiente, mientras que los próximos a cero muestran un bajo grado de pertenencia. Los valores de esas funciones de pertenencia son indicativos de la estructura del conjunto de datos, en el sentido de que si una función miembro tiene valores próximos a uno para dos vectores de X , esto es x_k, x_n , entonces estos vectores son considerados similares entre sí.

Volviendo a los conceptos introducidos a través de las ecuaciones (3.6) y (3.7) comenzamos nuestro estudio suponiendo que un vector puede pertenecer a más de un grupo y que cada grupo j de los m que tenemos está caracterizado o es representado por un vector de parámetros θ_j . En lo que sigue utilizamos la siguiente notación: $\theta \equiv [\theta_1^t, \theta_2^t, \dots, \theta_m^t]^t$, U es una

matriz de dimensión $n \times m$ cuyo elemento (i,j) es igual a $u_{ij}(x_i)$, $d(x_i, \theta_j)$ es la no similitud entre x_i y θ_j , y $q (>1)$ es un parámetro llamado *peso exponencial* o *difusor (fuzzifier)*. El papel de este parámetro se aclarará en más adelante.

Muchos de los algoritmos de agrupamiento difuso son los que se obtienen minimizando una función de coste de la forma dada en (3.8).

$$J_q(\theta, U) = \sum_{i=1}^n \sum_{j=1}^m u_{ij}^q d(x_i, \theta_j) \quad (3.8)$$

con respecto a θ y U , sujeto a las restricciones

$$\sum_{j=1}^m u_{ij} = 1, \quad i = 1, 2, \dots, n, \quad (3.9)$$

$$u_{ij} \in [0, 1], \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, m; \quad 0 < \sum_{j=1}^m u_{ij} < n, \quad j = 1, 2, \dots, m \quad (3.10)$$

En otras palabras, el grado de pertenencia de x_i al grupo j -ésimo está relacionado al grado de pertenencia de x_i al resto de los m grupos a través de (3.9). Dependiendo del valor de q en (3.8), la función $J_q(\theta, U)$ tiende bien hacia el agrupamiento difuso o hacia el agrupamiento puro.

Se suele emplear el siguiente algoritmo iterativo, para obtener las mejores estimas de U y θ ,

1. Elegir $\theta_j(0)$ como estimas iniciales para θ_j , $j = 1, \dots, m$
2. $t = 0$
3. Repetir hasta que se cumpla algún criterio de terminación
 - para $i = 1$ hasta n
 - para $j = 1$ hasta m

$$u_{ij}(t) = \sum_{j=1}^m \left(\frac{d(x_i, \theta_j(t))}{d(x_i, \theta_j(t))} \right)^{\frac{-1}{q-1}}$$

fin bucle j

fin bucle i

$t = t + 1$

para $j = 1$ hasta m

$$\text{Resolver } \sum_{i=1}^n u_{ij}^q(t-1) \frac{\partial d(x_i, \theta_j)}{\partial \theta_j} = \mathbf{0} \quad (3.11)$$

con respecto a θ_j y hacer $\theta_j(t)$ igual a esta solución

fin bucle j

Como criterio de terminación se puede emplear $\|\theta(t) - \theta(t-1)\| < \varepsilon$ donde $\|\cdot\|$ es cualquier norma vectorial y ε es una constante con un valor pequeño definida por el usuario.

Puntos representativos de los grupos.

En el caso de grupos compactos, se suele utilizar un vector como representante de cada grupo; esto es θ_j (que puede ser el vector media \mathbf{m}_j) consta de d parámetros. En este caso, la medida de similitud o de no similitud puede ser cualquier distancia $d(\mathbf{x}_i, \theta_j)$ entre dos puntos, por ejemplo consideremos la distancia de Mahalanobis,

$$d(\mathbf{x}_i, \theta_j) = (\theta_j - \mathbf{x}_i)^t C_j^{-1} (\theta_j - \mathbf{x}_i) \quad (3.12)$$

Este algoritmo es lo que se conoce como *Fuzzy c-Means* o *Fuzzy k-means*.

Existen diferentes índices o medidas escalares para validar la partición. El objetivo consiste en encontrar el número de clústeres que obtenga las mejores medidas de los índices:

a) *Coficiente de partición (CP)*: mide la cantidad de solapamiento entre los clústeres

$$CP = \frac{1}{n} \sum_{i=1}^m \sum_{j=1}^n (\mu_{ij})^2 \quad (3.13)$$

Cuanto más próximo sea este valor a la unidad tanto mejor será la clasificación de los datos, llegando a ser una participación pura cuando toma el valor de la unidad.

b) *Partición de entropía (PE)* o *Coficiente de entropía (CE)*:

$$PE = -\frac{1}{n} \sum_{i=1}^m \sum_{j=1}^n \mu_{ij} \log(\mu_{ij}) \quad (3.14)$$

En este caso, la mejor partición viene dada por el menor valor de este coeficiente.

3.3.2. Clasificador Bayesiano.

La teoría de la decisión de Bayes es un método estadístico clásico en clasificación de patrones. Se basa en el supuesto de que el problema de la decisión se enfoca en términos probabilísticos y que todas las probabilidades relevantes resultan conocidas.

Consideremos el problema de diseñar un clasificador para separar dos clases de elementos, en principio cada elemento tiene la misma probabilidad de ser M o A. De forma más precisa, suponemos que existe alguna probabilidad a priori $P(y=M)$ de que el siguiente elemento sea M y alguna probabilidad a priori de que sea un elemento A $P(y=A)$. Esas

probabilidades a priori reflejan nuestro conocimiento del modelo a representar. Ambas probabilidades $P(y=M)$ y $P(y=A)$ son no negativas y su suma es la unidad.

La única información sobre el fenómeno son esas probabilidades a priori, por tanto si tenemos que tomar una decisión, parece razonable utilizar la siguiente regla de decisión, decidir M si $P(y=M) > P(y=A)$, en caso contrario decidir A.

Si ahora ampliamos el número de tipos de elementos a clasificar hasta J y el número de atributos dados por el vector de atributos $\mathbf{x} = \{x_1, x_2, \dots, x_d\}$ estamos ante un problema de clasificación general. Utilizando el teorema de Bayes y considerando que tanto las probabilidades a priori $P(y = c_j)$ como las densidades condicionales para cada clase $p(\mathbf{x} / y = c_j)$ son conocidas o se pueden estimar, es posible determinar para una observación dada \mathbf{x} la probabilidad de que esa observación pertenezca a una determinada clase. Estas probabilidades, llamadas probabilidades a posteriori pueden usarse para construir una regla discriminante

$$p(y = c_j / \mathbf{x}) = \frac{p(\mathbf{x} / y = c_j)P(y = c_j)}{p(\mathbf{x})} \quad (3.15)$$

donde

$$p(\mathbf{x}) = \sum_{j=1}^c p(\mathbf{x} / y = c_j)P(y = c_j) \quad (3.16)$$

$P(y_i / \mathbf{x})$ es la probabilidad condicional de que la clasificación sea correcta. Minimizar el riesgo condicional significa maximizar $P(y_i / \mathbf{x})$, por lo que la regla de decisión considerando el error mínimo resulta

$$\mathbf{x} \in c_i \text{ sii } P(y = c_i / \mathbf{x}) > P(y = c_j / \mathbf{x}) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.17)$$

Fijándose en el segundo término de la expresión (3.15) del teorema de Bayes y habiendo eliminado el término no discriminante $p(\mathbf{x})$, se tiene una forma alternativa de clasificar un vector de atributos \mathbf{x} :

$$\mathbf{x} \in c_i \text{ sii } P(\mathbf{x} / y = c_i)P(y = c_i) > P(\mathbf{x} / y = c_j)P(y = c_j) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.18)$$

Generalmente las distribuciones de densidad de probabilidad se eligen Normales o Gaussianas para la mayoría de los casos prácticos en reconocimiento de patrones. Un caso especial surge cuando las probabilidades a priori son iguales para todas las clases, ya que en esta situación la distancia de Mahalanobis se puede utilizar como función discriminante mediante la siguiente regla de decisión a partir de (3.18) y teniendo en cuenta el signo negativo en el término exponencial de la función de densidad de probabilidad Normal, así

$$\mathbf{x} \in c_i \text{ sii } d_M^2(\mathbf{x}, \mathbf{m}_i) < d_M^2(\mathbf{x}, \mathbf{m}_j) \quad \forall i \neq j, \quad i, j = 1, 2, \dots, c \quad (3.19)$$

donde $\mathbf{m}_i, \mathbf{m}_j$ son los vectores media de las clases c_i y c_j respectivamente.

A veces puede resultar de interés conocer el grado de separabilidad entre dos clases c_i y c_j , para hacer su validación. Algunas de tales medidas son las que se proporcionan a continuación, que pueden encontrarse descritas en Jensen (1982) y Pinilla (1995).

Divergencia

$$Diverg_{ij} = 0.5Tr[(C_i - C_j)(C_j^{-1} - C_i^{-1})] + 0.5Tr[(C_i^{-1} - C_j^{-1})(\mathbf{m}_i - \mathbf{m}_j)(\mathbf{m}_i - \mathbf{m}_j)^t] \quad (3.20)$$

donde $Tr[\cdot]$ es la traza de una matriz (suma de los elementos de la diagonal principal), C_i y C_j son las matrices de covarianza de las clases c_i y c_j y \mathbf{m}_i y \mathbf{m}_j son los vectores media de las clases c_i y c_j , finalmente el superíndice t indica vector transpuesto.

Coseno del ángulo formado por los vectores media

$$\cos \alpha_{ij} = \frac{\mathbf{m}_i^t \mathbf{m}_j}{|\mathbf{m}_i| |\mathbf{m}_j|} \quad (3.21)$$

es evidente que a mayor paralelismo entre ambos vectores, las correspondientes clases serán más similares. Por tanto, un valor alto de $\cos \alpha$ expresa mayor similitud entre las clases.

Distancia de Jeffries-Matusita

$$J_{ij} = 2(1 - e^{-B}) \quad (3.22)$$

donde B es la distancia de *Bhattacharyya* dada por,

$$B_{ij} = \frac{1}{8} (\mathbf{m}_i - \mathbf{m}_j)^t \left(\frac{C_i + C_j}{2} \right)^{-1} (\mathbf{m}_i - \mathbf{m}_j) + \frac{1}{2} \ln \frac{2|(C_i + C_j)|}{\sqrt{|C_i|} \sqrt{|C_j|}} \quad (3.23)$$

donde $|C|$ indica el determinante de C . Cuanto mayor sea su valor mayor separabilidad.

3.3.3. Algoritmo generalizado de Lloyd.

A continuación vamos a describir el algoritmo generalizado de Lloyd (AGL) propuesto inicialmente por Lloyd (1957) y generalizado más tarde para cuantización vectorial por Linde y col. (1980). Este algoritmo aplica las dos condiciones necesarias a los datos de entrenamiento para determinar cuantizadores vectoriales óptimos minimizando el riesgo empírico, el algoritmo que exponemos aquí utiliza un método de aproximación estocástica. En realidad el método propuesto a continuación es una versión modificada del AGL original y se conoce como algoritmo de aprendizaje competitivo en la literatura de redes neuronales.

1) Inicio: dados los puntos de datos $\mathbf{x}(k)$, $k = 1, 2, \dots$, y centros de salida iniciales $\mathbf{c}_j(0)$, $j = 1, \dots, m$

2) Determinar el centro $\mathbf{c}_j(k)$ más próximo al punto $\mathbf{x}(k)$

$$j = \arg \min_j L(\mathbf{x}(k), \mathbf{c}_j(k)) \quad (3.24)$$

utilizando la función de error al cuadrado como función de pérdidas. Esto se simplifica para obtener la regla del vecino más próximo

$$j = \arg \min_j \|\mathbf{x}(k) - \mathbf{c}_j(k)\| \quad (3.25)$$

El hallazgo del centro más próximo se denomina competición (entre centros) en los métodos de redes neuronales.

3) Actualizar el centro de salida utilizando las ecuaciones,

$$\begin{aligned} \mathbf{c}_j(k_j + 1) &= \mathbf{c}_j(k_j) - \gamma(k_j) [\mathbf{x}(k) - \mathbf{c}_j(k_j)] \\ k_j &= k_j + 1 \end{aligned} \quad (3.26)$$

que se conoce comúnmente como regla de aprendizaje competitivo en redes neuronales.

Obsérvese que cada centro puede tener su propia razón de aprendizaje, lo que se indica con k_j en $\gamma(k_j)$, con $j = 1, \dots, m$. La razón de aprendizaje $\gamma(k_j)$ debe cumplir las condiciones de aproximación estocástica.

Un problema común en el AGL es que una mala elección de los centros iniciales desemboca en soluciones óptimas localmente malas.

3.3.4. Self-Organizing Maps (SOM).

Es uno de los métodos más populares en redes neuronales para la reducción de la dimensionalidad. El método Self-Organizing Map (SOM) como otros muchos modelos en el campo de las redes neuronales fue propuesto originalmente como una aplicación de un fenómeno biológico.

En el modelo que presentamos, el espacio de salida \mathfrak{R}^m puede discretizarse en un conjunto de valores llamado el *mapa (map)*. Los vectores \mathbf{z} en este espacio de características sólo toman valores de este conjunto. Un requisito importante de este conjunto es que existe una distancia entre los miembros del mapa.

El conjunto de valores finitos del espacio de características es

$$\Psi = \{\psi_1, \psi_2, \dots, \psi_b\} \quad (3.27)$$

Los elementos de este conjunto son únicos, de forma que pueden especificarse de forma unívoca bien por sus índices o por sus coordenadas en el espacio de características. Utilizaremos la notación $\psi(j)$ para indicar el elemento ψ_j del conjunto ψ .

Puede representarse como un conjunto finito de *centros*, a menudo llamadas *unidades*

$$\mathbf{c}_j = F(\psi(j), w), \quad j = 1, \dots, b \quad (3.28)$$

El objetivo es estimar los valores de las unidades \mathbf{c}_j . Esto se lleva a cabo mediante el correspondiente algoritmo SOM, que desarrollamos a continuación en términos de aproximación estocástica.

Condiciones de partida: Dado un espacio de características discreto $\psi = \{\psi_1, \psi_2, \dots, \psi_b\}$, los puntos $\mathbf{x}(k)$ y las unidades $\mathbf{c}_j(k)$, con $j = 1, \dots, b$ con el índice discreto k .

1. Determinar la unidad más próxima al dato $\mathbf{x}(k)$, que se conoce como la unidad vencedora,

$$\mathbf{z}(k) = \psi \left(\arg \min_j \|\mathbf{c}_j(k-1) - \mathbf{x}(k)\|^2 \right) \quad (3.29)$$

2. Actualizar todas las unidades utilizando la ecuación de actualización,

$$\begin{aligned} \mathbf{c}_j(k) &= \mathbf{c}_j(k-1) + \gamma(k) K_{\alpha(k)}(\psi(j), \mathbf{z}(k)) [\mathbf{x}(k) - \mathbf{c}_j(k-1)] \\ k_j &= k_j + 1 \end{aligned} \quad (3.30)$$

con $j = 1, \dots, b$

3. Decrementar la razón de aprendizaje $\gamma(k)$ y el ancho de la vecindad $\alpha(k)$.

La razón de aprendizaje $\gamma(k)$ debe cumplir las condiciones de aproximación estocástica. K_α es una *función de vecindad* con un parámetro $\alpha(k)$ que define el ancho de la función o zona de influencia de la misma y que a su vez se le permite que varíe con k .

Una característica de este algoritmo es el decrecimiento gradual del ancho de la función de vecindad a medida que progresan las iteraciones. La descripción original del SOM no especifica cómo debe decrecer el ancho de la función de vecindad, por lo que su elección suele hacerse basándose en pruebas de ensayo y error para una determinada aplicación. No obstante las siguientes definiciones son usuales tanto para K_α como para $\alpha(k)$,

$$K_{\alpha(k)} = (\mathbf{z}, \mathbf{z}') = \exp \left(-\frac{\|\mathbf{z} - \mathbf{z}'\|^2}{2\alpha^2(k)} \right) \quad \text{con} \quad \alpha(k) = \alpha_{inicial} \left(\frac{\alpha_{final}}{\alpha_{inicial}} \right)^{k/k_{max}} \quad (3.31)$$

donde k es el número de iteración y k_{max} es el número máximo de iteraciones, que se especifica por el usuario. El ancho inicial de la vecindad $\alpha_{inicial}$ se elige de modo que la vecindad cubra todas las unidades y el ancho final de la vecindad α_{final} controla el grado de variación del núcleo entre iteraciones consecutivas, estos parámetros son fijos una vez establecidos.

3.4. Identificación mediante análisis de movimiento.

3.4.1. Método de Lucas-Kanade.

De entre los tres grandes grupos de problemas relacionados con el análisis del movimiento desde un punto de vista práctico, nos centraremos en este caso en la detección del movimiento.

La detección del movimiento es el problema más sencillo. Se trata de registrar cualquier movimiento detectado. Es útil en el campo de la seguridad y aplicaciones similares, donde se suele utilizar una simple cámara estática.

El análisis del movimiento a partir de una secuencia de imágenes se encamina hacia la estimación del movimiento relativo entre los objetos en la escena y las imágenes. Uno de los métodos más importantes para la estimación del movimiento está basado en el gradiente. Esto es, en la observación del cambio de los niveles de intensidad en la imagen. El *flujo óptico* refleja los cambios de la imagen debido al movimiento durante un intervalo de tiempo dt y el campo de flujo óptico es el campo de velocidad que representa el movimiento tridimensional de puntos de los objetos a través del movimiento bidimensional de la imagen.

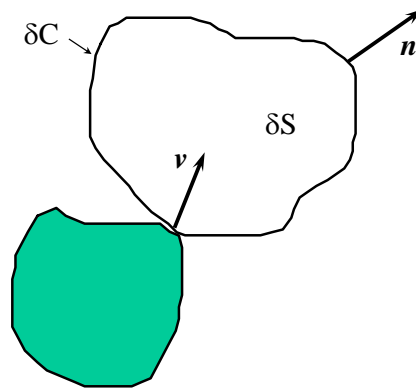


Figura 6: Definición de símbolos para la ecuación de restricción del flujo óptico

Considerando una analogía con la ecuación de continuidad de fluidos, se puede obtener la correspondiente ecuación de restricciones (Nomura y col., 1994) observando un cambio temporal de la intensidad de la imagen en un área local δS ,

$$\frac{\partial}{\partial t} \int_{\delta S} f ds = - \oint_{\delta C} f \mathbf{v} \cdot \mathbf{n} dc + \int_{\delta S} \phi ds \quad (3.32)$$

donde $f(x,y,t)$ es una distribución espacio temporal de intensidad de la secuencia de imágenes, δC es el contorno envolviendo δS , $\mathbf{v}=(u,v)$ es un vector velocidad a determinar, \mathbf{n} es un vector unitario *normal* apuntando hacia fuera del contorno δC y ϕ es la razón de generación de intensidad sobre un píxel en δS , figura 6. La generación de intensidad significa disminución o aumento de la intensidad en una imagen bajo iluminación no uniforme. En la ecuación (3.32) el cálculo de la integral a lo largo del contorno δC se transforma en el cálculo integral sobre δS por

el teorema de la divergencia de Gauss, por tanto la fórmula diferencial de la ecuación (3.32) queda como sigue:

$$\frac{\partial f}{\partial t} = -f \operatorname{div}(\mathbf{v}) - \mathbf{v} \cdot \operatorname{grad}(f) + \phi \quad (3.33)$$

Para resolver la ecuación anterior es habitual formular dos restricciones:

a) La divergencia de \mathbf{v} es nula ($\operatorname{div}(\mathbf{v}) = 0$) (Nomura y col. 1994).

b) La intensidad observada para cualquier punto de un objeto es constante en el tiempo bajo las condiciones específicas de movimiento de las cámaras o movimiento de los objetos en la escena, lo que significa que la razón de generación de intensidad de un píxel ϕ es nula (Nalwa, 1993, Sonka 1995). Esta restricción es quizás un tanto exigente como sostiene Nalwa y sólo sería válida por ejemplo para superficies Lambertianas, que se trasladan bajo iluminación homogénea invariante en el tiempo, por ejemplo no hay fuentes de luz moviéndose en el entorno.

Con estas dos restricciones la ecuación (3.33) se transforma en

$$\frac{\partial f}{\partial t} + \mathbf{v} \cdot \mathbf{G} = 0 \quad (3.34)$$

donde por simplicidad de notación $\operatorname{grad}(f)$ es \mathbf{G} . Este gradiente \mathbf{G} es el gradiente espacial de una imagen bidimensional en la localización (x,y) .

La ecuación (3.34) es fundamental para los cálculos del flujo óptico. La ecuación es realmente un desarrollo en serie de Taylor de primer orden para la variación espacio temporal de la intensidad de la imagen (Sonka 1995, Ballard and Brown, 1982).

$$-f_t = f_x \frac{dx}{dt} + f_y \frac{dy}{dt} \quad (3.35)$$

Ahora el objetivo es obtener la velocidad $\mathbf{v} = \left(\frac{dx}{dt}, \frac{dy}{dt} \right) = (u, v)$ sabiendo que f_x, f_y y f_t son todas cantidades medibles o al menos puede obtenerse una medida aproximada a partir de $f(x,y,t)$.

La ecuación (3.35) es idéntica a la ecuación (3.34). Se puede observar a partir de cualquiera de estas dos ecuaciones que la diferencia de intensidad f_t en la misma localización (x,y) de la imagen en los instantes t y $t+dt$ es un producto de la diferencia del nivel de intensidad espacial y la velocidad en dicha localización de acuerdo al observador.

La ecuación anterior asume que durante el movimiento la intensidad de la imagen permanece constante a lo largo de la trayectoria s del movimiento, resultando $df/ds = 0$. Esto implica entre otras las siguientes consideraciones: cualquier cambio en la intensidad de la imagen se debe al movimiento, la iluminación de la escena permanece constante o las superficies de los objetos son opacas (superficies Lambertianas). En ocasiones la suposición de que la intensidad permanece constante no es cierta, particularmente si la iluminación cambia,

para evitar esta posibilidad se aplica la restricción de gradiente constante a lo largo de la trayectoria del movimiento por tanto, se recurre a la consideración de que a pesar de que pueda violarse la restricción de intensidad constante lo que si va a permanecer constante a lo largo de dicha trayectoria es el gradiente, esto es $d\nabla f/ds = 0$.

Método local: Lucas-Kanade

Teniendo en cuenta este hecho, la ecuación anterior se expresa como sigue

$$\begin{bmatrix} \partial^2 f / \partial x^2 & \partial^2 f / \partial x \partial y \\ \partial^2 f / \partial x \partial y & \partial^2 f / \partial y^2 \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = - \frac{\partial(\tilde{\nabla} f)}{\partial t} \quad (3.36)$$

considerando un entorno de vecindad Ω alrededor de cada punto sobre el que se extiende el sumatorio, la ecuación (3.36) se puede expresar como sigue,

$$\begin{bmatrix} \sum_{\Omega} f_x^2 & \sum_{\Omega} f_x f_y \\ \sum_{\Omega} f_x f_y & \sum_{\Omega} f_y^2 \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = - \begin{bmatrix} \sum_{\Omega} f_t f_x \\ \sum_{\Omega} f_t f_y \end{bmatrix} \equiv A \mathbf{v} = \mathbf{b} \quad (3.37)$$

La solución de la ecuación (3.37) puede obtenerse por mínimos cuadrados,

$$\mathbf{v} = (A^T A)^{-1} A^T \mathbf{b} \quad (3.38)$$

En la figura 7 se muestran dos imágenes consecutivas (a) y (b) dentro de una secuencia y en (c) el resultado de aplicar la ecuación (3.38).



Figura 7: Imágenes consecutivas de la misma secuencia, y flujo óptico correspondiente.

CAPÍTULO 4. APLICACIÓN DE LOS MÉTODOS PROPUESTOS. RESULTADOS OBTENIDOS.

4.1. Planteamiento práctico.

La aplicación de los métodos propuestos, con el fin de alcanzar los objetivos establecidos, se puede diferenciar en dos partes: una la captura de muestras en el entorno y circunstancias determinadas y otra mediante las técnicas de Visión por Computador descritas previamente, de las imágenes obtenidas.

Para conseguir las imágenes de fuego se ha procedido a la combustión de diferentes elementos en un entorno perfectamente controlado y seguro. Se ha realizado la toma de diversas muestras, unas cien por entorno, ya que al ser un ambiente externo, conlleva la dificultad de capturar un número suficiente de ellas con la calidad mínima para ser tratadas analíticamente y poder sacar resultados concluyentes.

De entre todas las imágenes capturadas, en el primer escenario, fuego de gas, se analizaron 15 imágenes CV y 20 imágenes CT, utilizando 6 de cada tipo en la presentación de resultados de esta memoria; en el segundo escenario, fuego de líquido, se analizaron 20 imágenes CV y 20 imágenes CT, empleando 5 de cada cámara en los resultados; y en el tercer escenario, fuego sólido, se ha procedido del mismo modo que para el segundo escenario de fuego líquido.

Se considera que los resultados expuestos son representativos de cada escenario, no existiendo diferencias apreciables entre las diferentes imágenes capturadas de cada tipo.

Como se ha comentado en el apartado correspondiente sobre la teoría del fuego, existen diferencias entre la combustión de un tipo de combustible y otro: por ello se ha procedido a la ignición de un material sólido, restos de un palé de madera en el interior de un cubo metálico; material líquido, gasoil en el interior también de un cubo metálico; y de un material gaseoso, propano, a través de una instalación canalizada de una fuga controlada.

Para la obtención de las imágenes se han empleado dos cámaras diferentes⁴:

- Cámara térmica, Dräger modelo UCF 6000 (2018), que captura imágenes en escala de grises representando la intensidad luminosa de los cuerpos debido a la emisión de radiación por la temperatura de éstos. Es una cámara con sensor de infrarrojos, resolución de 160 x 120 píxeles y una sensibilidad de temperatura nominal de 0,035 °C. Es un equipo muy robusto, fiable y seguro empleado habitualmente por las brigadas profesionales de bomberos en sus intervenciones. Este modelo concreto no posee memoria interna suficiente, por lo que se conecta directamente a un ordenador portátil con el software de captura propio de Dräger, para el almacenamiento de imágenes.

⁴ Las características técnicas completas aparecen en el *Anexo A*.

- Cámara digital compacta, Panasonic DMC-TZ20 (2018), para la obtención de imágenes en color y su análisis en los canales RGB.

La captura de imágenes se ha realizado simultáneamente con ambos equipos, con el fin de conseguir las mismas condiciones del entorno, dónde se ha podido comprobar que al encontrarse en un medio exterior que depende fuertemente de las condiciones ambientales, la adquisición debe hacerse de forma meticulosa y sistemática. Se realiza la toma de varias muestras en cada caso, para poder aplicar los métodos propuestos, en los que es necesario la comparación de imágenes consecutivas como en el análisis de movimiento, o en la creación de una base de datos con los valores, como en los métodos de aprendizaje y clasificación.

Para la segunda parte, el análisis y procesamiento de las imágenes, se ha utilizado el entorno de trabajo Matlab™ (Matlab, 2017), en el cual se han aplicado los algoritmos de los diferentes métodos a estudiar, ya existentes en la literatura (Pajares y Cruz, 2007), modificándolos convenientemente para las circunstancias concretas.

Para la identificación de las imágenes durante la descripción de los experimentos se emplea la siguiente nomenclatura, con el fin de facilitar su identificación y el seguimiento de dichos experimentos:

- FG Fuego gas, FL fuego líquido, FS fuego sólido.
- CV cámara digital compacta operando en el espectro visible, CT cámara térmica.
- XX número de imagen.
- MOTx imagen obtenida con el método de umbralización de Otsu, x umbrales x+1 regiones coloreadas.
- Bayes, Fuzzy, Lloyd y SOM, imágenes resultantes de aplicar los algoritmos de aprendizaje y clasificación según el Clasificador Bayesiano, Fuzzy K-means, Generalizado de Lloyd o Self-Organizing Maps respectivamente.
- LK -- -- XY imagen resultante de aplicar la detección de movimiento por el método de Lucas-Kanade a las imágenes respectivas X e Y.

Como entrada de cada algoritmo se utilizan las imágenes capturadas con la cámara CV o CT según proceda en cada caso, y como salida se genera la representación correspondiente al resultado de aplicar el algoritmo según el método propuesto.

De este modo obtendremos imágenes coloreadas por regiones, variando el número de umbrales a considerar según el método de Otsu; imágenes coloreadas según el patrón de clasificación de texturas que consideremos en los métodos de aprendizaje y clasificación; o el mapa de flujo óptico, para la detección de movimiento según el método de Lucas-Kanade.

En los siguientes apartados se analizarán detenidamente cada uno de ellos, presentando las imágenes originales que se han analizado, los resultados e imágenes que se han obtenido en dicho análisis y se evalúan las diferencias entre métodos con las conclusiones más importantes extraídas sobre la validez y aplicabilidad de los mismos.

El análisis realizado es de carácter cualitativo ya que cuantitativamente no se dispone de imágenes de referencia o Ground Truth.

4.2. Método de umbralización de Otsu.

En este caso se emplean, como se ha comentado anteriormente, imágenes en escala de grises, capturadas con la CT.

La idea es identificar el fuego en aquellos lugares de la escena, al ser estos puntos de mayor temperatura y emisión de radiación, que presentarán los valores más altos de intensidad y aparecerán con colores más claros, mientras que el fondo y los objetos más fríos sucederá lo contrario al encontrarse a menor temperatura y por lo tanto más oscuros.

El método de Otsu, estima los valores umbral que separan unas regiones de otras, y de esta forma localiza las zonas que corresponderían al proceso de combustión. En la forma aquí aplicada el número de valores umbral (y el de regiones en consecuencia, al ser uno más que el número de umbrales) es desconocido y resulta uno de los principales inconvenientes de este método, siendo necesario aplicar distintos valores a una misma imagen para comprobar su validez.

El exceso de regiones puede ser tan contraproducente como el defecto, pues lo que queremos es determinar exactamente las zonas buscadas, intentando no identificar zonas erróneas sin fuego como tal y al contrario, zonas con fuego que no sean identificadas. De ahí la importancia de valorar correctamente el número de umbrales múltiples en este tipo de métodos.

El programa que implementa el algoritmo se denomina *Multiumbral.m*, siendo necesario adaptar los parámetros como el número de umbrales, y el nombre de los archivos para funcionar correctamente.

La función *multithresh*, realiza automáticamente el algoritmo del método de umbralización de Otsu, limitándose el resto del programa a preparar la imagen para su tratamiento y presentación.

En la imagen coloreada resultante, donde cada color identifica un rango de niveles de intensidades distinto, figura 11, se puede comprobar como cada uno de los colores asignados se corresponde con cada una de las regiones a considerar.

Fuego de gas.

En la imagen siguiente, figura 8, tomada con la CV, aparece el escenario de la fuga de gas. La primera fotografía, a la izquierda, corresponde a un campo de prácticas contra incendios, en el que se pueden ver varios proyectos de entrenamiento, sin fugas ni procesos de combustión. La segunda fotografía, a la derecha, es el mismo escenario, pero en esta ocasión existe una fuga de gas en una de las conducciones, que además se encuentra incendiada.



Figura 8: Escenario de la fuga de gas.

La llama que surge aparece con una intensidad alta, debido a la energía que se desprende en el proceso de la combustión. Esta región de intensidad más elevada que el resto es la que se pretende etiquetar y localizar según el método propuesto.

En las imágenes FG CT 00, FG CT 01 y FG CT 02, mostradas la figura 9 de izquierda a derecha respectivamente, se presenta el escenario capturado con la cámara térmica, sin la presencia de combustión, ya que es necesario un tiempo de demora desde la apertura de la válvula en el tanque de propano, hasta que llega a la salida, donde se produce la fuga y la ignición. Se observa la imagen en escala de gris como se esperaba, los objetos más fríos se muestran más oscuros, como el cielo y las nubes, mientras que los elementos más calientes, tanques y tuberías, se muestran más brillantes.




Figura 9: Imágenes del escenario de gas tomadas con la cámara térmica y sin combustión.

El histograma de las imágenes se obtiene fácilmente aplicando la función *histogram* en Matlab, sobre la imagen correspondiente. De este modo se comprueba la distribución de intensidades en la figura 10, para la imagen FG CT 00 de la figura 9. (Para las imágenes FG CT 01 y FG CT 02, el histograma resultante es similar).




Figura 10: Histograma con la distribución de intensidades para la imagen FG CT 00.

Claramente se percibe en el histograma que los dos valores máximos de la distribución coinciden con el 0 y el 255, valor más oscuro y valor más claro, que corresponden al fondo y a los objetos a mayor temperatura respectivamente, quedando el resto de objetos de la escena distribuidos en los valores intermedios.

En este caso, los valores de los umbrales se almacenan en una variable, dando como resultado:

$$\text{Thres (FG CT 00)} = [31, 88, 141, 204]$$

Como se puede comprobar, son valores en los que aproximadamente se encuentra un mínimo local, separando las distribuciones de intensidad diferentes.

Si ahora lo representamos gráficamente, las imágenes obtenidas mediante el método multinivel propuesto basado en Otsu para 4 umbrales (5 regiones) son respectivamente las presentadas en la figura 11, MOT4 FG CT 00, MOT4 FG CT 01 y MOT4 FG CT 02:

El histograma de intensidades con toda la gama de grises, es dividido por 4 valores y agrupado de este modo en 5 regiones, que se encuentran identificadas con su etiqueta correspondiente, identificada por el color representado en la imagen. Para mejorar su visualización las regiones etiquetadas se colorean de diferente manera. Así, los valores de intensidad similar que se encuentran entre dos umbrales consecutivos, son clasificados con la misma etiqueta y en este caso aparecen del mismo color.




Figura 11: Imágenes obtenidas por el método de multiumbralización de Otsu, con 4 umbrales.

En estas imágenes se aprecia otro fenómeno interesante. Al circular el gas por la tubería, éste se despresuriza y por lo tanto se enfría⁵. En una secuencia de imágenes consecutivas, como las anteriores, se puede visualizar el progreso del gas a través del conducto al disminuir notablemente la temperatura, llegando incluso a la congelación de la canalización o la válvula de apertura.

Este hecho podría utilizarse para la localización y control de fuga de gases licuados o a alta presión, incluso para vapores no visibles o con alto riesgo de inflamación previo a su ignición.



Figura 12: Conducto de gas, antes y después de circular el fluido por él.

En la imagen de la figura 12 se señala la brida de gas con el conducto, antes de circular el gas por él y después de atravesarlo el fluido. Como se ha comentado la intensidad es menor en los materiales a menor temperatura y aparecen más oscuros en la imagen capturada con la CT, etiquetándose apropiadamente en las imágenes MOT4 FG CT 00, MOT4 FG CT 01 y MOT4 FG CT 02 de la figura 11.

⁵ Según la ecuación de los gases ideales $PV = nRT$, por lo que si disminuye la presión, se reduce la temperatura.

En la secuencia de imágenes mostradas en la figura 13, se representa una fuga de gas en combustión (parte superior), imágenes FG CT 03, FG CT 04 y FG CT 05, junto con los resultados obtenidos mediante la aplicación del método de multiumbralización (parte inferior), imágenes MOT4 FG CT 03, MOT4 FG CT 04 y MOT4 FG CT 05 respectivamente.

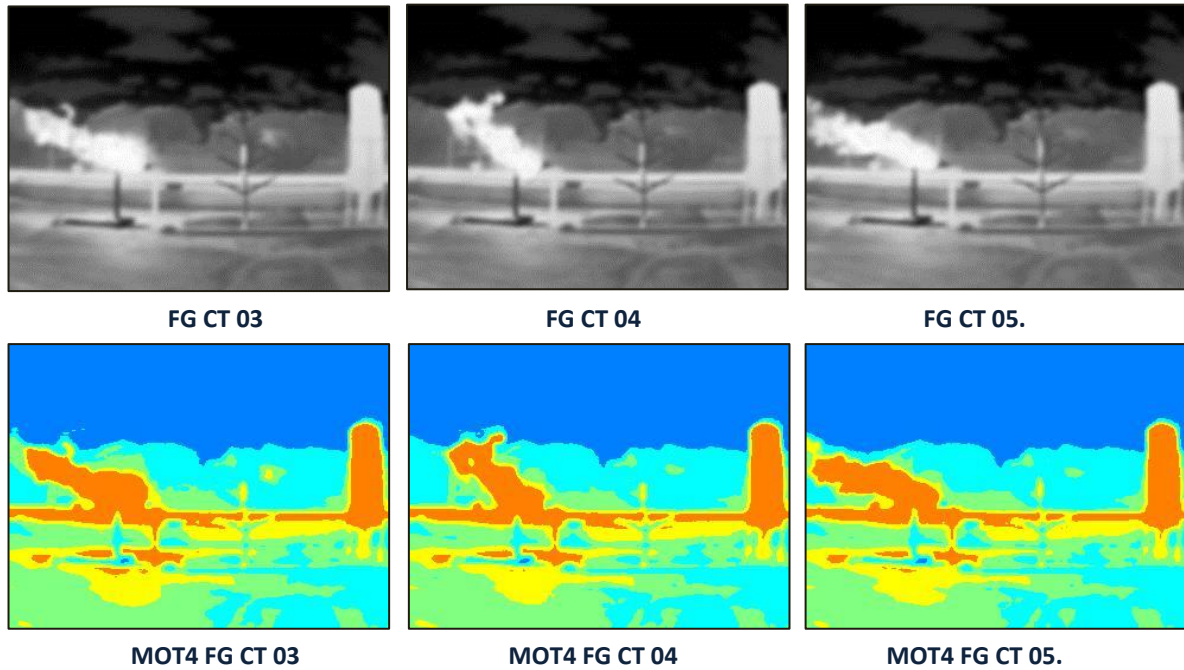


Figura 13: Imágenes de gas en combustión con cámara térmica y al aplicar el método de Otsu, $n=4$.

El histograma resultante de la imagen FG CT 03 de la figura 13 se muestra en la figura 14, donde se observa que es diferente al anterior de la imagen FG CT 00.




Figura 14: Histograma con la distribución de intensidades para la imagen FG CT 03.

En este caso el valor máximo de la distribución en 255, valor más claro, ha desaparecido, pues la CT convenientemente ha registrado con los valores más elevados al proceso de la combustión, que lógicamente se presenta en menor número de píxeles que en el otro histograma, de la figura 10.

Los valores de los umbrales son en este caso:

$$\text{Thres (MOT4 FG CT 03)} = [57, 111, 148, 192]$$

De este modo, en estas imágenes la llama de la combustión corresponde a la parte más brillante de la escena, pero el método de multiumbralización resulta insuficiente con 4 umbrales y 5 regiones, ya que no es capaz de distinguir el fuego de otros objetos que no se encuentran en combustión, como el tanque o las tuberías, etiquetándolas de la misma manera y sin conseguir el objetivo de la identificación unívoca del fuego.

Es necesario, aplicar el algoritmo con un número de umbrales mayor, para ver si en estas condiciones, se puede diferenciar correctamente lo que es el fuego de lo que no lo es.

Procederemos a aplicar un número de 7 umbrales y otro de 9, para comprobar la aplicabilidad del método y sus resultados.


Con $n = 7$, los valores de los umbrales para la imagen FG CT 03 son:

$$\text{Thres (MOT7 FG CT 03)} = [25, 71, 106, 129, 155, 187, 218]$$


Y para $n = 9$, los valores obtenidos en la misma imagen son:

$$\text{Thres (MOT9 FG CT 03)} = [25, 48, 79, 107, 126, 148, 175, 201, 231]$$

En la figura 13, se toma la imagen FG CT 03 (primera por la izquierda de la parte superior) y se obtienen las representaciones MOT7 FG CT 03 y MOT9 FG CT 03, de la figura 15. En este caso, con $n = 7$, se mejora notablemente la diferenciación entre regiones, pero se aprecia aún, que el fuego está etiquetado del mismo modo que la parte superior del depósito.



MOT7 FG CT 03



MOT9 FG CT 03

Figura 15: Imágenes con 7 umbrales (8 regiones) y 9 umbrales (10 regiones).

Es necesario llegar a $n = 9$ umbrales, para poder distinguir correctamente la llama del resto. Incluso en estas circunstancias, puesto que la llama no se encuentra igual a la misma temperatura, partes de ella tienen la misma etiqueta que otros elementos.

Sólo los valores superiores a 231 (umbral más elevado para $n = 9$) son identificados como fuego. Mientras que los valores entre 201 y 231 se etiquetan de igual manera, a pesar de corresponder a elementos diferentes como el humo, tuberías o depósitos.

Comprobando la validez de este método para la detección de fuegos, se ha constatado que es necesario un número elevado de umbrales para la obtención de resultados satisfactorios, número que a priori se desconoce, y además no identifica de forma unívoca los elementos a etiquetar.

El motivo de este resultado, es que el método de Otsu se basa en el análisis de la distribución de intensidad de los píxeles de la imagen, es decir en el número de píxeles existentes en una determinada región con respecto al total de píxeles de la imagen. Por lo tanto si el fuego no representa un porcentaje elevado de la superficie de la imagen total analizada, no tendrán un peso significativo en la distribución, y no se distinguirán adecuadamente.

Esto puede suponer un inconveniente importante si nuestro objetivo, como se comentó en la introducción, es detectar fuegos en su fase inicial, antes de que se encuentren muy evolucionados y con gran dimensión.

Fuego de líquido.

En este caso el fuego es en un cubo con gasoil, combustible líquido. El escenario planteado es el que se representa en las imágenes de la figura 16, con la imagen del recipiente previo a la ignición y una toma con el fuego presente:



Figura 16: Escenario de fuego líquido previo y en combustión.

Las imágenes térmicas, capturas con la CT, en este caso son FL CT 00 (sin llama), FL CT 02 y FL CT 04 (con llama y humo), mostradas en la figura 17.

Se puede ver en este caso como en el anterior, las llamas a mayor temperatura, se manifiestan más brillantes, e incluso el humo aparece igualmente en tonos más claros, al estar igualmente a temperatura muy elevada. Objetos como el recipiente y la puerta metálica reflejan también la radiación y por lo tanto son mostrados con valores de intensidad altos en las imágenes CT.




Figura 17: Imágenes térmicas de la combustión líquida.

Si comprobamos del mismo modo que con el combustible en forma de gas, el histograma extraído de las imágenes térmicas, obtenemos así la figura 18, para la imagen FL CT 00 (figura 17) previa a la ignición.




Figura 18: Histograma con la distribución de intensidades para la imagen FL CT 00.

Se observa en esta ocasión un eminente predominio de los tonos oscuros, del entorno de la puerta, mientras que los objetos metálicos a mayor temperatura (a partir de 110 en el eje de abscisas de la figura 18) se muestran más claros.

En el caso de la imagen FL CT 02 de la figura 17 con presencia del proceso de combustión, el histograma obtenido es ahora el siguiente, figura 19:




Figura 19: Histograma con la distribución de intensidades para la imagen FL CT 02.

En lo que respecta a la distribución de los valores de intensidad varía notablemente con respecto a la imagen sin fuego. La imagen se presenta mucho más oscura (nótese que en la figura 18 hay unos 6.000 píxeles con valor 0 y en la figura 19 hay 16.000⁶), teniendo en cuenta el cambio de escala en el eje de ordenadas, ya que la CT destaca principalmente los




Figura 20: Imágenes con el método de umbralización de Otsu, para 4 umbrales y 5 regiones.

⁶ La imagen consta de $320 \times 240 = 76.800$ píxeles en total.

elementos que se encuentran a alta temperatura, contrastando con el fondo, pero que no suponen un porcentaje elevado en el total de la imagen.

Mediante la aplicación del algoritmo de Otsu, sobre las imágenes FL CT 00, FL CT 02 y FL CT 04 de la figura 17, se obtienen los resultados mostrados en la figura 20, MOT4 FL CT 00, MOT4 FL CT 02, MOT4 FL CT 04. Inicialmente, como en el caso anterior de la combustión de gases, se procede a aplicar 4 valores umbrales y etiquetar 5 regiones.

Cuando no hay llama como en la imagen FL CT 00 de la figura 17, superficies de la puerta se representan como el cubo, al estar a similar temperatura, MOT4 FL CT 00 en la figura 20.

Posteriormente, al existir combustión, imágenes MOT4 FL CT 02 y MOT4 FL CT 04 en la figura 20, aparecen las llamas y el humo que se identifican correctamente, pero el recipiente se encuentra etiquetado del mismo modo que el fuego, pues aumenta marcadamente su temperatura y consecuentemente la radiación emitida

Los valores obtenidos como umbrales en cada una de las imágenes se almacenan en la variable, y son por lo tanto para cada una de las tres imágenes consideradas:

Thres (MOT4 FL CT 00) = [44, 109, 158, 189];

Thres (MOT4 FL CT 02) = [42, 94, 142, 201];

Thres (MOT4 FL CT 04) = [48, 109, 154, 207];

El cuarto valor de la variable Thres (189 sin fuego y 201, 207 con fuego), es a partir del cual se identifica la etiqueta con los valores de mayor intensidad, los que corresponden al fuego y los elementos a mayor temperatura. Como era de esperar, con fuego es más alto este valor que sin él, pues hay mayor número de píxeles en ese rango del histograma (concentrándose en torno a 250) minimizando la varianza ponderada, tal cómo define el método el valor umbral a seleccionar.

Para la imagen FL CT 01 de la figura 21, si se aumentan el número de valores umbrales, del mismo modo que con los gases, obtenemos las imágenes MOT 4 FL CT 01, MOT7 FL CT 01 y MOT9 FL CT 01 de la figura 22, se comprueba el resultado:





Figura 21: Imagen térmica FL CT 01 y su histograma de intensidad correspondiente.

En la figura 21, también se muestra el histograma de la imagen FL CT 01, que cómo se puede observar es similar al de la imagen FL CT 02 de la figura 19.

En el caso de la imagen MOT4 FL CT 01 de la figura 22, los valores resultantes para los umbrales con $n = 4$ son:

$$\text{Thres (MOT4 FL CT 01)} = [35, 77, 116, 174];$$

Para $n = 7$ obtenemos 7 valores umbrales y 8 regiones etiquetadas para los correspondientes rangos de intensidad entre dos valores consecutivos:

$$\text{Thres (MOT7 FL CT 01)} = [31, 68, 93, 120, 158, 191, 225];$$

Y finalmente para $n = 9$ el resultado es:

$$\text{Thres (MOT9 FL CT 01)} = [14, 43, 74, 100, 129, 167, 199, 223, 241];$$




Figura 22: Imagen térmica etiquetada con 4, 7 y 9 umbrales respectivamente.

Ahora se diferencian mejor las regiones según su temperatura, resultando que el cubo se refleja a mayor valor que la llama y el humo. Con este método se podrían detectar superficies calientes sobre el resto, y los gases en combustión se mostrarían diferentes de las mismas. De esta forma se ha comprobado cómo a mayor número de umbrales el etiquetado de los elementos de la imagen se hace mucho más preciso. Se distingue perfectamente cada etiqueta según la temperatura a la que se encuentra (y en consecuencia la radiación emitida que es capturada por la CT).

Si nuestro objetivo es la detección temprana, antes de que el fuego se encuentre muy evolucionado y presente grandes llamas o humo abundante, el método necesitaría un número de umbrales elevado para identificarlo adecuadamente, pero si lo que se necesita es la comprobación de conductos o tanques de almacenamiento que contengan líquido en combustión no necesariamente visibles, sería capaz incluso de etiquetar por zonas y elementos a diferente temperatura, o mostrar cómo superficies próximas al fuego se ven afectadas y se calientan, figura 22 imagen MOT9 FL CT 01.

Fuego de sólido.


Para el estudio de los fuegos sólidos, el escenario es idéntico al planteado con combustible líquido. En esta ocasión lo que se queman son restos de madera en un recipiente como en el caso anterior, aunque los elementos sólidos emiten menos humo y llama al tener una combustión en forma de brasas y a menor temperatura, debiendo producirse la pirólisis previa a la ignición.

El escenario planteado se muestra en la figura 23, obtenido con la CV, dónde se pueden observar las imágenes del material sólido en el cubo antes de prenderle fuego, y posteriormente cuando ya se encuentra ardiendo, emitiendo llamas y humo.



Figura 23: Escenario de fuego sólido, inicial y en combustión.

Las imágenes térmicas capturas con la CT son para los sólidos, las mostradas en la figura 24, FS CT 00 imagen previa a la ignición, FS CT 01 y FS CT 02, imágenes con las maderas ardiendo y emitiendo llamas, humo y radiación:



FS CT 00

FS CT 01

FS CT 04

Figura 24: Imágenes de fuego sólido. Sin combustión (FS CT 00) y con combustión.

En el histograma obtenido, figura 25, para la imagen FS CT 00 de la figura 24, se puede apreciar que el número de los píxeles de la imagen con valor 0 (negro) son una inmensa mayoría (próximo a 25.000), por lo que para obtener una representación más informativa, se

realiza una adaptación de la escala mostrando únicamente el intervalo [20,255] de intensidades de los píxeles en lugar del completo [0 255].




Figura 25: Histograma de la imagen FS CT 00. Intervalos [0,255] y [20,255] respectivamente.

Los valores umbrales de intensidad al aplicar el método de Otsu con $n = 4$ en este caso resultan:

$$\text{Thres (MOT4 FS CT 00)} = [40, 98, 151, 212];$$

A partir de esos valores se puede apreciar que es una imagen con un contraste elevado entre un fondo extenso muy oscuro de la pared y las superficies brillantes del recipiente y su entorno. También se percibe un rango de valores de intensidad abundante entre 50 y 150 correspondientes a la puerta.

El histograma para las imágenes FS CT 01 y FS CT 04 de la figura 26, resulta ser similar y dónde se considera el rango de valores [20, 255], pues como en el caso anterior el número de píxeles con valor 0 es muy elevado (> 20.000) y no representa adecuadamente la información.




Figura 26: Histogramas de intensidades para las imágenes FS CT 01 y FS CT 04, respectivamente.

Los valores umbrales de intensidad al aplicar el método de Otsu con $n = 4$ en este caso resultan:

$$\text{Thres (MOT4 FS CT 01)} = [27, 77, 135, 199];$$

$$\text{Thres (MOT4 FS CT 04)} = [23, 70, 127, 194];$$

Siendo similares para ambas imágenes.

A partir de estos umbrales podemos etiquetar la imagen en 5 zonas y representarlas coloreadas para su mejor identificación, figura 27:




Figura 27: Resultado de aplicar el método de Otsu ($n = 4$) a imágenes FS CT 00, FS CT 01 y FS CT 04.

En la primera imagen MOT4 FS CT 00, sin fuego, están a mayor temperatura las superficies metálicas, como en el caso del combustible líquido. La pared concentra la mayor parte de la información de la imagen en los valores oscuros, presentando la puerta una temperatura superior, y por encima de ésta el cubo y el entorno del mismo. El combustible de madera, sin arder, aparece dentro de los valores más bajos.

En las imágenes con fuego MOT4 FS CT 01 y MOT4 FS CT 04, figura 27, debido al bajo número de umbrales seleccionados en el método, el recipiente, las llamas y el humo se clasifican con la misma etiqueta. La parte de la puerta que refleja la radiación se clasifica con otras etiquetas distintas, según su proximidad a la combustión y por último la pared con el valor más bajo.

Si aumentamos el número de umbrales según el método de Otsu para la imagen FS CT 01, figura 24, consecuentemente, dispondríamos de más etiquetas en la imagen, con las que poder distinguir con mayor precisión los elementos.

De este modo se obtienen las imágenes MOT7 FS CT 01 y MOT9 FS CT 01, para $n = 7$ y $n = 9$, respectivamente, figura 28.

Los valores umbrales obtenidos se pueden comprobar en el histograma anterior, figura 26, y son:

$$\text{Thres (MOT7 FS CT 01)} = [21, 51, 85, 123, 164, 202, 233];$$

$$\text{Thres (MOT9 FS CT 01)} = [19, 49, 80, 110, 134, 158, 180, 205, 232];$$




Figura 28: Imágenes de las regiones identificadas según el método de Otsu con $n = 7$ y $n = 9$.

En este caso no se diferencia el combustible sólido del recipiente que lo contiene, según las imágenes registradas por la CT, ambos elementos se encuentran a la misma temperatura.

Para etiquetar de distinto modo el humo y las llamas de la madera o el cubo es necesario un número elevado de umbrales que los identifiquen convenientemente, con $n = 7$ podría ser suficiente. En la puerta, mayor número de etiquetas, segrega más las zonas de la misma que emiten radiación, cuánto más próximas al foco del incendio mayor temperatura.

En el combustible líquido se apreciaba menos este fenómeno, posiblemente debido a la mayor emisión de humo, que enmascara la radiación emitida por detrás por la puerta.

4.3. Reconocimiento de patrones.

La estrategia empleada en esta ocasión varía sustancialmente con la utilizada hasta ahora. Si antes se realizaba el estudio sobre el histograma de intensidad de los píxeles capturados por una cámara térmica CT, ahora se trabaja sobre imágenes en color RGB capturadas por una cámara operando en el espectro visible CV. Antes detectábamos los cambios de temperatura en el escenario planteado y ahora se trabaja sobre fenómenos de combustión con llama visible en dicho escenario.

Por lo tanto, la primera diferencia es precisamente ésta, para poder identificar el incendio correctamente con estos métodos, es necesario que exista fuego o humo que sean visibles y contrastables con el resto de elementos de la imagen.

Para llevar a cabo esta tarea, se emplean métodos de reconocimiento de patrones, con el fin de clasificar los objetos en diferentes categorías o clases. Conocidos los atributos de un determinado elemento, los elementos siguientes que tengamos se pueden clasificar dentro de esa misma categoría en base a sus propios atributos. En este caso los atributos son los

valores de los canales RGB, R (red – rojo), G (green – verde) y B (blue – azul), que varían desde 0 a 255 inclusive⁷.

Pero como bien se ha comentado, los atributos de un elemento deben ser conocidos, por lo que es imprescindible realizar una fase de aprendizaje en la que se definen las clases con sus atributos, a partir de las imágenes previas, creando una base de datos con la información necesaria para realizar un tratamiento estadístico de la distribución. Posteriormente, las nuevas imágenes que obtengamos se validan contra esa base de datos y permiten la clasificación de sus elementos.

En nuestro caso, lo que se pretende es diferenciar el fuego por su color del resto de elementos de la escena. Para ello, se emplean los programas *Aprendizaje.m* y *Clasificador.m* (Pajares y Cruz, 2007) ejecutados en MatlabTM (2017), modificados convenientemente para nuestro propósito y seleccionando los algoritmos aplicados, Fuzzy K-means, clasificador bayesiano, generalizado de Lloyd y SOM.

Con el programa *Aprendizaje.m* se definen las clases existentes, siendo establecido el número de clases a identificar en 4, y una vez escogida la imagen o imágenes previas, se seleccionan con el ratón los diferentes píxeles con los que formar la base de datos. Lógicamente, cuánto mayor sea el número de muestras, mejor se define la distribución, intentando además que las muestras sean representativas de las clases a etiquetar. Este programa almacena los datos en dos archivos diferentes *ParamAprendizaje.mat*, con los parámetros del proceso de aprendizaje y *MuestrasAprendizaje.mat*, con los valores seleccionados y que forman la base de datos del conocimiento en sí.

Una vez establecidos los parámetros según los métodos elegidos y almacenados en los archivos antes mencionados, se puede proceder a la clasificación de imágenes. Se etiqueta cada uno de los píxeles en una de estas 4 clases, coloreando de forma diferente las mismas para su visualización más oportuna.

En el: *Anexo B*, se recogen las muestras de los valores seleccionados en las imágenes, 100 valores para cada tipo de fuego considerado, gas, líquido y sólido, con sus respectivas componentes RGB en cada valor.

Fuego de gas.

Para el aprendizaje utilizaremos las imágenes FG CV 01 y FG CV 02, figura 29, seleccionando 50 píxeles con el ratón en cada una de ellas, por lo que la base de datos con las muestras tendrá 100 valores, intentando elegir de todas las texturas presentes. Posteriormente se pueden añadir nuevos elementos si fuera necesario.

⁷ [0 – 255] => 2⁸ valores por canal, lo que nos da: 2⁸ x 2⁸ x 2⁸ = 2²⁴ = 16.777.216 combinaciones de colores posibles.



FG CV 01



FG CV 02

Figura 29: Imágenes de fuego de gas para el aprendizaje en el reconocimiento de patrones.

Fuego de líquido.

Para el caso de fuego líquido en el escenario planteado, se procede del mismo modo que con el fuego de gas, empleando en esta ocasión las imágenes FL CV 01 y FL CV 04 de la figura 30. Se toman de nuevo 50 muestras en cada imagen, sobre una base de datos nueva, para no interferir con los resultados anteriores⁸.



FL CV 01



FL CV 04

Figura 30: Imágenes de fuego de líquido para el aprendizaje en el reconocimiento de patrones.

Fuego de sólido.

En el fuego de sólido, para la madera, se realiza el aprendizaje del mismo modo que en las anteriores, sobre las imágenes FS CV 02 y FS CV 03, figura 31, creando un nuevo archivo de muestras.

⁸ Posteriormente se analiza la clasificación sobre el aprendizaje de imágenes de distinto tipo de fuego.



FS CV 02



FS CV 03

Figura 31: Imágenes de fuego de sólido para el aprendizaje en el reconocimiento de patrones.

Se procede a continuación a comprobar los métodos de aprendizaje y la clasificación de nuevas imágenes con los algoritmos apropiados.

4.3.1. Fuzzy K-means.

En esta ocasión, como ya se explicó en la parte teórica, se realiza una agrupación de los elementos en las diferentes clases o “clústeres”, pero asociándolos con un grado de pertenencia a cada una de ellas (agrupamiento difuso). Cada clase queda representada por su centro y la distribución de elementos.

Los parámetros elegidos para el método son: $m = 2$ (peso exponencial o difusor) $\epsilon = 0,01$ (parámetro de terminación), $c = 4$ (clases).

La matriz $X1$ almacena los 100 registros (con los 3 valores de los 3 canales RGB respectivamente) desde 0 a 255 sin normalizar. Los centros calculados de las 4 clases se almacenan en el vector v .

Fuego de gas.

La representación cartesiana en los ejes RGB, como se planteó en la figura⁹ 2, para este caso concreto se muestra en la figura 32, donde se simbolizan los 100 valores como puntos negros, y además se pueden observar los centros calculados para las 4 clases establecidas.

Como se puede apreciar, los puntos seleccionados en las imágenes siguen un determinado patrón de comportamiento, tal como era de esperar, correspondiente a las diferentes texturas que aparecen en las imágenes.

⁹ En la figura 2 el origen de coordenadas es distinto, pero no afecta a su visualización.




Figura 32: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego de gas.

Una proyección bidimensional de los datos y centros de las clases se muestra en la figura 33, ya que la figura en tres dimensiones puede dar lugar a confusión en su visualización.

Las variables principales que almacenan los valores calculados y necesarios para este algoritmo son:

- $X1$, ya mencionada, como matriz de 100×3 , 100 registros seleccionados y sus valores RGB de $[0, 255]$.
- X , la misma matriz anterior normalizada para el rango $[0, 1]$.
- $DATOS_CLASES$, donde se puede comprobar el número de valores en cada clase (25, 23, 27 y 25 respectivamente) y las clases con sus puntos asignados. Los centros calculados de cada una de las clases, $vFuzzy$, y el grado de pertenencia de cada uno $UFuzzy$.
- U , matriz de 100×4 , donde se calcula el grado de pertenencia de cada punto a cada una de las clases.
- $CValidezFuzzy$, donde se almacenan los coeficientes de validación de la partición CP y CE.




Figura 33: Proyección bidimensional de los puntos y centros de las clases. Fuego de gas.

De este modo los centros obtenidos para cada clase son:

$$V_1 = [196, 213, 227] \rightarrow \text{Color} = \text{XXX} \text{ (cielo);}$$

$$V_2 = [204, 139, 62] \rightarrow \text{Color} = \text{XXX} \text{ (fuego);}$$

$$V_3 = [143, 145, 144] \rightarrow \text{Color} = \text{XXX} \text{ (suelo);}$$

$$V_4 = [26, 35, 20] \rightarrow \text{Color} = \text{XXX} \text{ (vegetación);}$$

Y los coeficientes de validación, ya explicados en la parte teórica:

$$CP = 0'90$$

Siendo CP el Coeficiente de Partición, que representa el solapamiento entre clases. Cuanto más próximo sea a la unidad, mejor es la separación entre las mismas, correspondiendo el caso extremo de la unidad a la partición pura.

Y

$$CE = 0'17$$

Donde CE es el Coeficiente de Entropía o Partición de Entropía, relacionado como indica su nombre con el desorden de los datos en la clase, en este caso se define mejor la partición cuanto más bajo es el valor.

Una vez realizada la fase de aprendizaje y teniendo definidas las clases, se procede a la fase de clasificación. Para ello empleamos el algoritmo, sobre tres imágenes diferentes en el mismo escenario, con el fin de probar la capacidad de detección de las texturas antes seleccionadas.

El programa realiza un submuestreo de la imagen, para no tener que procesar la imagen completa y a continuación para cada uno de los nuevos píxeles es calculado su grado de pertenencia a cada clase, seleccionando aquel cuyo valor sea mayor.

Para su visualización se colorea cada clase de un modo distinto, comprobando el resultado final. La matriz *FUZZY*, almacena los valores de las clases y la *ClasesFuzzy* las etiquetas asignadas a las mismas

La primera imagen es la FG CV 04, con su correspondiente imagen coloreada de la clasificación Fuzzy FG CV 04, figura 34.




Figura 34: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means.

En la figura 34, se aprecia perfectamente la figura del fuego, en esta ocasión coloreada como verde. Se pueden comprobar las cuatro clases existentes, el cielo coloreado de rojo, el pavimento coloreado de azul, el campo y la hierba coloreados de amarillo y el fuego como se ha comentado coloreado de verde.


Está claro según lo expuesto, que para una correcta clasificación es necesaria una buena fase de aprendizaje, con una selección de muestras adecuadas de cada una de las clases a diferenciar.

Se manifiesta también en las clases que no corresponden al fuego, cómo hay elementos que no se etiquetan correctamente, por ejemplo nubes en el cielo o depósitos sobre el campo, pues el color que poseen no se diferencia lo suficiente sobre el resto y puede llegar a identificarse erróneamente, como es el caso.

La siguiente imagen y su clasificación se muestran en la figura 35. En esta ocasión, se procede a etiquetar un escenario idéntico, pero sin combustión.



FG CV 00



Fuzzy FG CV 00

Figura 35: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means.

Como se esperaba, al no existir fuego, no se etiqueta ninguna zona como tal en la imagen, verificando el correcto funcionamiento del método.

Para terminar con los fuegos de gases, se aplica sobre la imagen FG CV 05 de la figura 36, donde la combustión representa una superficie mínima de la imagen.



FG CV 05



Fuzzy FG CV 05

Figura 36: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Fuzzy K-means.

Aún con combustiones de llama mínima, el algoritmo es capaz de detectarlas y clasificarlas correctamente. Para una mejor diferenciación se podría modificar el factor de submuestreo y analizar con mayor precisión, a expensas de un coste computacional mayor.

En las imágenes escogidas, con fuego, sin fuego y con una llama pequeña, se ha realizado correctamente la distinción del mismo. A diferencia de los métodos de umbralización no

depende de la cantidad de píxeles en la imagen en su clasificación, sino de la presencia de una determinada textura o patrón en la misma.

Como conclusión, para los fuegos de gas, se demuestra la validez del algoritmo Fuzzy K-means, como método de aprendizaje y clasificación, en la detección de procesos de combustión con llama visible. Es necesario insistir en la importancia de la fase de aprendizaje, y en la adecuada selección de muestras, para una correcta generación de las clases, pues como se ha podido comprobar no todas las clases distinguen exactamente los elementos.

Fuego de líquido.

Se procede a hacer un planteamiento similar para las imágenes de fuego líquido. En esta ocasión la representación cartesiana RGB para las muestras seleccionadas es la siguiente, figura 37, con los centros obtenidos según el algoritmo de agrupamiento difuso.




Figura 37: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego líquido.

Con la consiguiente proyección bidimensional de los datos en la figura 38.




Figura 38: Proyección bidimensional de los puntos y centros de las clases. Fuego líquido.

Existen 4 clases con 30, 36, 24 y 10 muestras cada una de ellas. Los centros obtenidos respectivamente para cada clase son:

$$V_1 = [184, 187, 181] \rightarrow \text{Color} = \text{XXX (puerta)};$$

$$V_2 = [119, 116, 94] \rightarrow \text{Color} = \text{XXX (pared y suelo)};$$

$$V_3 = [228, 142, 70] \rightarrow \text{Color} = \text{XXX (fuego)};$$

$$V_4 = [36, 36, 36] \rightarrow \text{Color} = \text{XXX (cubo y zonas ennegrecidas)};$$

Y los coeficientes de validación, que en comparación con el caso del fuego de gas son ligeramente diferentes, en esta ocasión resulta una agrupación peor definida:

$$CP = 0'89$$


$$CE = 0'21$$

Procediendo del mismo modo, imagen con llama y humo, imagen sin llama e imagen con llama pequeña, se pueden comprobar los resultados obtenidos en el proceso de clasificación, y la representación gráfica de las imágenes que se presenta en las siguientes figuras.

Imagen FL CV 05 y Fuzzy FL CV 05, figura 39, fuego con llama visible y humo.



FL CV 05



Fuzzy FL CV 05

Figura 39:: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Fuzzy K-means.


Se aprecia la zona de fuego, aunque mínima, correctamente identificada y coloreada de azul. La puerta y tonos claros de la pared son rojos, el muro y suelo son verdes y las zonas oscuras o tiznadas de humo negro (y el cubo quemado) son las amarillas

Se comprueba que el humo negro, normalmente asociado a hidrocarburos y combustibles con alto poder calorífico como es el caso, enmascara a parte de la llama, lo cual puede ser un problema si llegara a ser muy abundante y nuestro objetivo sea localizar la llama.

Para el escenario previo a la combustión, tenemos la imagen FL CV 00 con su representación Fuzzy FL CV 00, de la figura 40.



FL CV 00




Fuzzy FL CV 00

Figura 40: Imagen del escenario previo y su representación de la clasificación según el algoritmo Fuzzy K-means.

Donde correctamente, no hay ninguna zona etiquetada como fuego.

Por último, para el fuego líquido, probamos el algoritmo con una llama pequeña.



FL CV 02

Fuzzy FL CV 02

Figura 41: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Fuzzy K-means.

En esta ocasión, se etiqueta adecuadamente, pero se percibe la dificultad para ello, al ser la llama demasiado pequeña y no existir suficientes valores en dicha clase, por lo que podría ser necesario un submuestreo menor o no realizar muestreo alguno, manteniendo la imagen original, con el consiguiente aumento del cálculo computacional.

Fuego de sólido.

Para el fuego sólido la representación cartesiana RGB de las muestras y los centros de las clases es, figura 42.




Figura 42: Representación cartesiana RGB de las muestras usadas para el aprendizaje. Fuego sólido.

La proyección bidimensional es la que se muestra en la figura 43.




Figura 43: Proyección bidimensional de los puntos y centros de las clases. Fuego de gas.

Se percibe que hay una gran dispersión de los datos con respecto a los centros de las clases.

Las 4 clases tienen cada una 19, 29, 23 y 29 muestras, con sus centros respectivos:

$$V_1 = [172, 184, 186] \rightarrow \text{Color} = \text{XXX (puerta)};$$

$$V_2 = [140, 130, 115] \rightarrow \text{Color} = \text{XXX (pared)};$$

$$V_3 = [237, 178, 112] \rightarrow \text{Color} = \text{XXX (fuego)};$$

$$V_4 = [70, 67, 54] \rightarrow \text{Color} = \text{XXX (zonas oscuras)};$$

Y los coeficientes de validación, con valores similares al caso del fuego líquido, son el Coeficiente de Partición y el Coeficiente de Entropía.

$$CP = 0'89$$


$$CE = 0'22$$

Comprobamos ahora el resultado de aplicar el algoritmo de clasificación, sobre una imagen de fuego sólido con llama, del escenario previo a la ignición con las maderas sin arder y con llama pequeña en presencia de humo y con las maderas de color oscuro que han empezado a quemarse.

Imagen FS CV 05, con su representación Fuzzy FS CV 05, figura 44.



FS CV 05



Fuzzy FS CV 05

Figura 44: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Fuzzy K-means.

El fuego se etiqueta correctamente y se muestra de color azul. La puerta y zonas claras son de color rojo, la pared y el humo son de color verde y el suelo, cubo y maderas quemadas de color amarillo.

La imagen previa del escenario con las maderas sin arder, imagen FS CV 00 y Fuzzy FS CV 00, figura 45.



FS CV 00



Fuzzy FS CV 00

Figura 45: Imagen del escenario y su representación de la clasificación según el algoritmo Fuzzy K-means.

Al no existir proceso de combustión, no se etiqueta ninguna zona como tal. Las maderas que todavía no se han quemado, se clasifican con la etiqueta de la pared, y lógicamente no hay presencia de humo, por lo que la superficie identificada como puerta es mayor. Sin embargo, se presentan puntos aislados etiquetados como fuego siendo en realidad zonas oscuras de la madera, lo cual es un inconveniente.

Para fuego de sólido con una llama mínima, intentamos la clasificación del mismo modo, en esta ocasión con las imágenes FS CV 01 y su correspondiente Fuzzy FS CV 01, figura 46.




Figura 46: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Fuzzy K-means.

Como se puede apreciar, la identificación es mínima, apenas unos píxeles, por lo que es necesario recurrir a la variable que almacena los datos *ClasesFuzzy*, con la pertenencia a cada una de las clases para verificar la existencia de fuego.

La llama es pequeña y queda oculta en parte por la presencia del humo, los puntos identificados erróneamente como fuego en la figura 45, ya no existen al quemarse la madera.

4.3.2. Clasificador Bayesiano.

En este método de clasificación nos basaremos en la teoría de la decisión de Bayes, ya expuesta en el capítulo teórico correspondiente.

El algoritmo *Bayesian.m* en *Aprendizaje.m* realiza la media y la covarianza de las muestras seleccionadas, para una distribución cuya densidad de probabilidad es conocida. Posteriormente se comprueba su validez a través de los parámetros calculados *Divergencia*, *Coseno Alpha* (coseno del ángulo formado por los vectores media) y *Jeffries – Matusita* (distancia de Jeffries – Matusita), también definidos en el apartado teórico.

El Clasificador Bayesiano, en *Clasificador.m*, calcula la distancia de Mahalanobis, la cual nos va a determinar la probabilidad de pertenencia de cada uno de los píxeles considerados en la nueva imagen a cada clase. El valor mínimo de dicha distancia corresponderá a la máxima probabilidad.

Los valores obtenidos en dicha clasificación se almacenan en la variable *ClasesBayes*, para posteriormente presentarlos en la imagen coloreada.

Utilizaremos las clases y sus centros calculados en el aprendizaje por Fuzzy K-means.

Fuego de gas.

La media de las clases seleccionadas y la covarianza necesaria en este algoritmo se almacenan en `DATOS_CLASES`, `mediaBayes` y `covarianzaBayes`, así las medias son:

$m_1 = [197, 212, 221] \rightarrow \text{Color} = \text{XXX}$ (cielo);

$m_2 = [201, 143, 67] \rightarrow \text{Color} = \text{XXX}$ (fuego);

$m_3 = [142, 145, 146] \rightarrow \text{Color} = \text{XXX}$ (suelo);


$m_4 = [28, 36, 20] \rightarrow \text{Color} = \text{XXX}$ (vegetación);

Realizamos la fase de clasificación según este método, para las mismas imágenes que las empleadas en el agrupamiento difuso.

De este modo, se obtiene la imagen FG CV 04, con su correspondiente imagen coloreada Bayes FG CV 04 con los elementos clasificados que se muestran en la figura 47.



FG CV 04



Bayes FG CV 04

Figura 47: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.

La imagen FG CV 00 de escenario sin fuego de gas, con su clasificación Bayes FG CV 00, en la figura 48. Para comprobar que no se detectan erróneamente, elementos de llama en



FG CV 00



Bayes FG CV 00

Figura 48: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.

combustión en entornos donde no los hay.

Para poner a prueba el algoritmo con una imagen de difícil clasificación, con una llama pequeña en el entorno, se emplea de nuevo la imagen FG CV 05 y su asociada Bayes FG CV 05, en la figura 49.



FG CV 05 **Bayes FG CV 05**
Figura 49: Imagen de fuego de gas y su representación de la clasificación según el algoritmo Bayesiano.

Los resultados obtenidos en la clasificación son similares a los del algoritmo Fuzzy K-means. Se identifica correctamente el fuego, y se etiquetan como tal aquellas zonas que lo son.

En las imágenes clasificadas Bayes FG CV 04 y Bayes FG CV 05, se distinguen los contornos de las formas menos definidos que en la clasificación difusa. Ciertas sombras y puntos se etiquetan de forma equivocada, por su similitud con alguna de las otras clases, como por ejemplo el suelo o los bordes, aunque como se ha comentado no aplica al caso de la llama.

Fuego de líquido.

Del mismo modo que para el fuego de gas, aunque en distinto escenario, se obtienen los valores del fuego líquido. En este caso las medias son:

$$m_1 = [186, 187, 179] \rightarrow \text{Color} = \text{XXX (puerta)};$$

$$m_2 = [122, 118, 96] \rightarrow \text{Color} = \text{XXX (pared)};$$

$$m_3 = [225, 140, 71] \rightarrow \text{Color} = \text{XXX (fuego)};$$


$$m_4 = [35, 35, 35] \rightarrow \text{Color} = \text{XXX (zona oscuras)};$$

Las imágenes a emplear son las mismas que en la clasificación del apartado anterior, para poder comparar los resultados adecuadamente.

La imagen FL CV 05, recipiente con fuego líquido en combustión con llama y humo visibles, junto con la representación de su clasificación Bayes FL CV 05, figura 50.



FL CV 05




Bayes FL CV 05

Figura 50: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Bayesiano.

Escenario de fuego líquido, previo a la combustión, imagen FL CV 00 e imagen Bayes FL CV 00, en la figura 51.



FL CV 00




Bayes FL CV 00

Figura 51: Imagen del escenario de líquido y su representación de la clasificación según el algoritmo Bayesiano.

Combustión con llama mínima, FL CV 02 y Bayes FL CV 02, figura 52.



FL CV 02



Bayes FL CV 02

Figura 52: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo Bayesiano.

En esta ocasión se presenta un fenómeno interesante, ya que el depósito de combustible en la parte inferior izquierda de la imagen FL CV 00, figura 51, en el escenario previo a la combustión, aparece etiquetado como fuego de forma equivocada. Esto es debido a que es de color rojo y de las clases calculadas, la clase del fuego es la que presenta menor distancia según el algoritmo que estamos aplicando. Cabe recordar que en el algoritmo difuso expuesto en el apartado anterior no sucedía de esta manera.

Fuego de sólido.

Para el caso de fuego sólido se aplica del mismo modo el algoritmo y comprobamos las medias resultantes de cada clase:

$m_1 = [171, 183, 184] \rightarrow \text{Color} = \text{XXX (puerta)}$;

$m_2 = [140, 130, 115] \rightarrow \text{Color} = \text{XXX (pared)}$;


$m_3 = [235, 175, 111] \rightarrow \text{Color} = \text{XXX (fuego)}$;

$m_4 = [72, 68, 55] \rightarrow \text{Color} = \text{XXX (zona oscuras)}$;

En la figura 53, figura 54 y figura 55, se aplica sobre las imágenes del escenario de fuego sólido, FS CV 05, FS CV 00 y FS CV 01 en dicho orden. Como en el caso anterior, fuego de maderas, escenario sin fuego y fuego de madera con poca llama. Se obtienen las imágenes Bayes FS CV 05, Bayes FS CV 00 y Bayes FS CV 01, respectivamente.



FS CV 05




Bayes FS CV 05

Figura 53: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo Bayesiano.

La imagen Bayes FS CV 05, figura 53, es muy similar a la obtenida con el algoritmo Fuzzy, Fuzzy FS CV 05, figura 44, sin diferencias importantes e identificando correctamente el fuego.



FS CV 00



Bayes FS CV 00

Figura 54: Imagen del escenario de fuego sólido y su representación según el algoritmo Bayesiano.

En la figura 54, se puede apreciar de nuevo, del mismo modo que en el algoritmo Fuzzy, que las maderas sin arder presentan tonos identificados como fuego, en este caso con mayor claridad que antes.



FS CV 01



Bayes FS CV 01

Figura 55: Imagen de fuego sólido y su representación de la clasificación según el algoritmo Bayesiano.

La imagen Bayes FS CV 01, figura 55, apenas distingue las llamas, por la presencia de humo que las enmascara.

Como se ha podido ver, el clasificador bayesiano, a pesar de emplear las clases calculadas con el algoritmo difuso, estima distintos centros para estas clases, aunque como se puede comparar en el *Anexo D*, los valores de los centros para estos dos métodos apenas varían un 1 %. La diferencia fundamental se debe al método de clasificación, ya que el clasificador Fuzzy emplea el grado de pertenencia a través de la distancia euclídea y Bayes la distancia de Mahalanobis.

El método de Bayes presenta bordes más difusos, puntos aislados y en cierto modo mayor sensibilidad a las variaciones de las texturas.

Para comprobar la validez de las clases obtenidas se puede demostrar el grado de separabilidad de las mismas, para ello se adjuntan en el *Anexo C*, unas tablas comparativas con los datos de la divergencia, el coseno del ángulo formado por los vectores media y la distancia de Jeffries – Matusita.

Según estas tablas, se puede verificar que el fuego de gas presenta una clase bien definida, que permite diferenciarlo correctamente del resto de clases, ya que por ejemplo el coseno entre los ángulos de las medias es bajo y las distancias de Jeffries – Matusita (DJM), son elevadas. Por otro lado, las clases C_1 y C_3 , que corresponden al cielo y al pavimento tienen un coseno máximo, de la unidad, lo que podría explicar la clasificación errónea de puntos y zonas del suelo.

Para el fuego líquido, los valores menores del coseno, corresponden a la clase C_3 , la del fuego, lo que permite etiquetarlo correctamente de las otras clases. Mientras valores del coseno altos en la clase C_1 , de la puerta, producen en la misma etiquetados con clases como la C_2 del suelo, o en la pared a la derecha de la puerta. La clase C_4 correspondiente a zonas oscuras y quemadas también presenta una separabilidad apreciable como se comprueba en las imágenes, Bayes FL CV 00 y Bayes FL CV 02, figuras 51 y 52 respectivamente, acorde a los valores de la DJM. El etiquetado de objetos como el depósito de gasoil que se identifica como fuego al ser rojo, se debe por lo tanto a la similitud con esa clase, para distinguirlo correctamente sería necesario crear nuevas clases o definir las mejor.

En lo que respecta a los fuegos sólidos, los valores de la divergencia son menores y los de los cosenos mayores, lo que significa menor separación entre las clases, produciendo zonas menos definidas. La DJM entre la clase C_2 de la pared – suelo, y la clase C_4 de las zonas oscuras tiene un valor de 1'81, generando un etiquetado menos homogéneo y más difuso, en estas zonas. Las diferencias más destacadas se producen en este caso para la clase C_3 del fuego, clasificándolo adecuadamente.

4.3.3. Algoritmo generalizado de Lloyd.

Este algoritmo (AGL) también denominado de aprendizaje competitivo, en una primera fase de entrenamiento trabaja sobre una serie de imágenes diferentes, en las que se ha tomado un número de muestras suficientes y a partir de unos centros de salida iniciales, calcula la distancia desde las muestras escogidas a cada uno de ellos. El centro más próximo es seleccionado como representativo de la clase a la que pertenece la muestra.

Una vez hecho este proceso, lógicamente es necesario actualizar el centro de salida, como se vio en el apartado teórico según la ecuación 3.26, y calcular el nuevo centro que corresponde a esa clase. Es necesario aportar un valor a la razón de aprendizaje, en nuestro caso 0'1. El algoritmo continúa con el resto de las muestras tomadas en la imagen, hasta contabilizar todas ellas. El proceso se vuelve a repetir de nuevo del mismo modo que en la iteración anterior, con un número máximo de iteraciones de 1.000 o hasta alcanzar una tolerancia de 0'1.

En la segunda fase de clasificación, se calcula la distancia de cada uno de los puntos de la imagen a clasificar (o de un submuestreo de ésta) a los centros de salida obtenidos para las clases consideradas, seleccionando la clase a la que pertenece como aquella que se encuentra a distancia menor. Como en los anteriores algoritmos se escoge un número de 4 clases.

Fuego de gas.

Empleamos las mismas imágenes de la figura 29, FG CV 01 y FG CV 02, con las muestras obtenidas entonces para el aprendizaje.

Los centros de salida resultantes al aplicar el AGL, como se ha explicado anteriormente son:

$c_1 = [180, 200, 220] \rightarrow \text{Color} = \text{XXX}$ (puerta);

$c_2 = [227, 169, 82] \rightarrow \text{Color} = \text{XXX}$ (fuego);


$c_3 = [141, 141, 139] \rightarrow \text{Color} = \text{XXX}$ (suelo);

$c_4 = [25, 34, 17] \rightarrow \text{Color} = \text{XXX}$ (vegetación);

Para comparar resultados realizamos la clasificación sobre las mismas imágenes que en los algoritmos anteriores, FG CV 04, FG CV 00 y FG CV 05, en las figuras 56, 57 y 58, obteniendo las imágenes Lloyd FG CV 04, Lloyd FG CV 00 y Lloyd FG CV 05.



FG CV 04




Lloyd FG CV 04

Figura 56: Imagen de fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.



FG CV 00




Lloyd FG CV 00

Figura 57: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.



FG CV 05



Lloyd FG CV 05

Figura 58: Imagen de fuego de gas y su representación de la clasificación según el algoritmo de Lloyd.

Puesto que el método de aprendizaje es diferente, los centros obtenidos para las clases son distintos pero próximos, como se puede comprobar en el *Anexo D*.

El centro de la clase C_2 , fuego, se presenta con tonos más claros, por ejemplo, y el centro de la clase C_1 , cielo, es ligeramente más oscuro. A pesar de ello, las diferencias son mínimas entre el método Fuzzy y el método AGL, únicamente quizás el contorno de alguna nube, debido a la tonalidad más oscura del centro comentado C_1 , que al ser más oscuro, incluye en su clase más píxeles de las sombras de las nubes. También el fuego, al cambiar ligeramente su tonalidad, en la imagen Lloyd FG CV 05, figura 58, tiene más dificultad para identificarse.

Las diferencias con respecto al clasificador bayesiano y el AGL, son las mismas que entre el algoritmo de Bayes y el algoritmo difuso, pues como se ha comentado los resultados del aprendizaje de AGL y Fuzzy son similares, distinguiéndose del bayesiano en la clasificación.

Fuego de líquido.

Para el fuego de líquido, los centros de salida de las 4 clases son:

$c_1 = [193, 194, 178] \rightarrow \text{Color} = \text{XXX}$ (puerta);

$c_2 = [115, 112, 86] \rightarrow \text{Color} = \text{XXX}$ (pared);

$c_3 = [232, 146, 69] \rightarrow \text{Color} = \text{XXX}$ (fuego);


$c_4 = [34, 34, 35] \rightarrow \text{Color} = \text{XXX}$ (zona oscuras);

Calculados sobre las imágenes FL CV 01 y FL CV 04 de la figura 30.

Las imágenes clasificadas son FL CV 05, con su resultado Lloyd FL CV 05, figura 59.



FL CV 05




Lloyd FL CV 05

Figura 59: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo AGL.

La imagen del escenario FL CV 00, y su correspondiente imagen Lloyd FL CV 00, figura 60:



FL CV 00




Lloyd FL CV 00

Figura 60: Imagen del escenario de fuego líquido y su representación de la clasificación según el algoritmo AGL.

Y para las imágenes y Lloyd FL CV 02, figura 61.



FL CV 02



Lloyd FL CV 02

Figura 61: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo AGL.

En esta ocasión los centros de las clases, tienen una variación mínima en relación a los algoritmos antes expuestos, Anexo D.

Los resultados son prácticamente idénticos en este caso, para los métodos AGL y Fuzzy.

Fuego de sólido.

Para el fuego de sólido, los centros de salida de las 4 clases son:

$c_1 = [162, 158, 149] \rightarrow$ Color = XXX (puerta);

$c_2 = [113, 102, 87] \rightarrow$ Color = XXX (pared);

$c_3 = [239, 174, 104] \rightarrow$ Color = XXX (fuego);

$c_4 = [57, 55, 44] \rightarrow$ Color = XXX (zona oscuras);

Calculados sobre las imágenes FS CV 02 y FS CV 03 de la figura 31.

El resultado obtenido sobre las imágenes FS CV 05, FS CV 00 y FS CV 01 son las imágenes Lloyd FS CV 05, Lloyd FS CV 00 y FS CV 01, presentados en la figura 62, figura 63 y figura 64, respectivamente.



FS CV 05



Lloyd FS CV 05

Figura 62: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo AGL.



FS CV 00




Lloyd FS CV 00

Figura 63: Imagen de escenario de fuego sólido y su representación de la clasificación según el algoritmo AGL.



FS CV 01



Lloyd FS CV 01

Figura 64: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo AGL.

La aplicación del AGL en las imágenes de fuego sólido, genera unos centros para las clases más oscuras, con valores inferiores RGB, en todas las clases, pero visiblemente marcados en la C_1 y C_2 , la puerta y la pared-suelo, respectivamente, *Anexo D*.

Este hecho produce que las imágenes Lloyd, figura 63, presenten zonas de la pared como si fueran de la puerta, al etiquetar a ésta más oscura. El suelo se asocia con la clase pared por este motivo también.

El fuego se identifica igualmente mejor, al tener también estos valores ligeramente inferiores (en la escala RGB) y oscurecerse con el humo.

4.3.4. Self-Organizing Maps (SOM).

En esta ocasión se va a proceder al aprendizaje y clasificación de las imágenes por el Algoritmo Autoorganizativo o Self-Organizing Maps (SOM) descrito en la sección 3.3.4.

Este algoritmo, en ciertos aspectos similar al AGL, a partir de los centros iniciales llamados unidades y que se calculan como medias para las cuatro clases habituales consideradas, determina la unidad más próxima a cada uno de los puntos (muestras).

A continuación se actualizan todas las unidades según la ecuación 3.30, teniendo en cuenta que el ancho de la vecindad se calcula con la ecuación 3.31, con $\alpha_{\text{inicial}} = 0,1$ y $\alpha_{\text{final}} = 0,01$, la razón de aprendizaje es variable en esta ocasión. Se establece un umbral con valor de $T = 10^{-5}$, de forma que si la función de vecindad K_{α} para esa unidad y ese punto es mayor que el umbral, se considera que la muestra pertenece a la región definida por la unidad y se actualiza el valor de ésta. Se realiza del mismo modo para todas las muestras, actualizando las unidades cuando corresponda.

Se decrementa la razón de aprendizaje y el ancho de la vecindad.

Se prosigue de este modo con las siguientes iteraciones, hasta alcanzar el máximo establecido (1.000) o llegar a una tolerancia de 10^{-6} .

Una vez realizado el proceso de aprendizaje se puede pasar al proceso de clasificación. Para una nueva imagen dada, se calcula la distancia de cada uno de los píxeles de la imagen (o un subconjunto de ella) a las unidades o centros de las clases, seleccionando la pertenencia a aquella a la que es menor.

Fuego de gas.

Con las imágenes de la figura 29, FG CV 01 y FG CV 02, se realiza la fase de aprendizaje, empleando las mismas muestras que en los algoritmos anteriores.

Los centros de las clases o unidades resultantes una vez aplicado el algoritmo SOM:

$$c_1 = [191, 210, 227] \rightarrow \text{Color} = \text{XXX (puerta)};$$

$$c_2 = [201, 133, 50] \rightarrow \text{Color} = \text{XXX (fuego)};$$

$$c_3 = [137, 139, 139] \rightarrow \text{Color} = \text{XXX (suelo)};$$


$$c_4 = [18, 27, 15] \rightarrow \text{Color} = \text{XXX (vegetación)};$$

Se aplica el proceso de clasificación sobre las imágenes siguientes del mismo modo que en los otros casos. Así obtenemos:

Imágenes FG CV 04 y SOM FG CV 04, figura 65.



FG CV 04




SOM FG CV 04

Figura 65: Imagen de fuego de gas y su representación de la clasificación según el algoritmo SOM.

Imágenes FG CV 00 y SOM FG CV 00, figura 66.



FG CV 00




SOM FG CV 00

Figura 66: Imagen sin fuego de gas y su representación de la clasificación según el algoritmo SOM.

Imágenes FG CV 05 y SOM FG CV 05, figura 67.



FG CV 05



SOM FG CV 05

Figura 67: Imagen de fuego de gas y su representación de la clasificación según el algoritmo SOM.

Los centros de las clases, según el Anexo D, son muy similares a los obtenidos con los algoritmos Fuzzy y Bayes, la clase C_4 , vegetación y zonas más oscuras, tiene valores algo inferiores para las tres componentes RGB y se visualiza ligeramente más oscuro.

Las imágenes etiquetadas resultantes SOM son prácticamente iguales a las generadas con el método de Fuzzy K-means, y las diferencias con los algoritmos Bayesiano y AGL, son las mismas que las comentadas anteriormente entre éstos y el algoritmo difuso.

Fuego de líquido.

Para el fuego de líquido, los centros de salida de las 4 clases son:

$$c_1 = [182, 197, 201] \rightarrow \text{Color} = \text{XXX (puerta)};$$

$$c_2 = [109, 107, 90] \rightarrow \text{Color} = \text{XXX (pared)};$$

$$c_3 = [249, 158, 66] \rightarrow \text{Color} = \text{XXX (fuego)};$$


$$c_4 = [26, 30, 31] \rightarrow \text{Color} = \text{XXX (zona oscuras)};$$

Calculados sobre las imágenes FL CV 01 y FL CV 04 de la figura 30.

Las imágenes clasificadas son las siguientes. Imagen FL CV 05, SOM FL CV 05, figura 68.



FL CV 05




SOM FL CV 05

Figura 68: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo SOM.

Imagen FL CV 00, SOM FL CV 00, figura 69.



FL CV 00




SOM FL CV 00

Figura 69: Imagen del escenario de fuego líquido y su representación de la clasificación según el algoritmo SOM.

Imagen FL CV 02, SOM FL CV 02, figura 70.



FL CV 02



SOM FL CV 02

Figura 70: Imagen de fuego de líquido y su representación de la clasificación según el algoritmo SOM.

En esta ocasión, volviendo a referenciar al *Anexo D*, y contrastando los centros de las clases calculados, se puede observar que hay matices que varían con el tipo de fuego anterior. Por ejemplo, el centro C_1 , puerta, es más claro que en los otros métodos, o el fuego, centro C_3 , también presenta una tonalidad más clara.

Aun así, no existen tampoco diferencias reseñables entre las imágenes SOM, Fuzzy y AGL obtenidas al etiquetar las zonas.

En este escenario las diferencias principales se producen al comparar con el clasificador bayesiano, que emplea la distancia de Mahalanobis como método de clasificación para calcular la distancia de los diferentes píxeles a los centros de las clases, en lugar de la distancia euclídea que utiliza este algoritmo.

Fuego de sólido.

Para el fuego de sólido, los centros de salida de las 4 clases son:

$c_1 = [170, 184, 188] \rightarrow$ Color = XXX (puerta);

$c_2 = [150, 147, 132] \rightarrow$ Color = XXX (pared);

$c_3 = [250, 213, 121] \rightarrow$ Color = XXX (fuego);


$c_4 = [42, 40, 37] \rightarrow$ Color = XXX (zona oscuras);

Del mismo modo que en los otros algoritmos con calculados sobre las imágenes FS CV 02 y FS CV 03 de la figura 31.

Las imágenes clasificadas para esos centros son las siguientes. FS CV 05, SOM FS CV 05, figura 71.



FS CV 05



SOM FS CV 05

Figura 71: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo SOM.

Imagen FS CV 00 y SOM FS CV 00, figura 72.



FS CV 00



SOM FS CV 00

Figura 72: Imagen de escenario de fuego sólido y su representación de la clasificación según el algoritmo SOM.

Imagen FS CV 01 y SOM FS CV 01, figura 73.




Figura 73: Imagen de fuego de sólido y su representación de la clasificación según el algoritmo SOM.

Los centros de las clases se recogen en el *Anexo D*, con sus valores en las componentes RGB y el color asociado.

La clase C_3 , correspondiente al fuego, es más clara, con valores RGB más elevados, como también sucede con la clase C_2 , de la pared y el suelo, mientras que la clase C_4 , de las zonas quemadas y ennegrecidas es más oscura, con valores RGB más próximos al cero.

Esto produce que algunas de las zonas del suelo se presenten con menos etiquetas en amarillo (como zona quemada), al estar más alejadas del centro C_4 , y el fuego identificado tenga menos relevancia que en el algoritmo Fuzzy (figura 44, imagen Fuzzy FS CV 05), al encontrarse más similar a la clase C_2 que a la clase adecuada C_3 . De hecho, en la figura 73, imagen SOM FS CV 01, no es capaz de detectar el fuego cuando otros algoritmos sí.

4.3.5. Conclusiones de los métodos de reconocimiento.

Los métodos de reconocimiento de patrones por medio de técnicas de aprendizaje y clasificación aquí expuestos, han demostrado ser eficaces en las condiciones adecuadas para la detección de incendios. Aunque como se ha podido comprobar, es un proceso no exento de dificultades e inconvenientes es esta tarea que puede dar lugar fácilmente a resultados erróneos.

Se ha demostrado que la fase de aprendizaje es fundamental para poder realizar posteriormente una correcta fase de clasificación. Los elementos que influyen en esta primera fase son el escenario a evaluar, el número y distribución de muestras seleccionadas, las clases en las que se van a agrupar, la diversidad de elementos en el entorno y la similitud entre ellos, las variaciones del entorno, la presencia de elementos que enmascaren o confundan la textura a diferenciar, entre otros.

Para el algoritmo Fuzzy K means, la clasificación se realiza de forma adecuada, incluso para fuegos de pequeña intensidad, siempre y cuando la distribución de las muestras se realice correctamente, y la clase a diferenciar contraste suficientemente con las otras presentes. Hay que tener precaución a la hora de interpretar los resultados, que la llama del fuego no resulte ocultada por otros factores como el humo o restos de la combustión.

El clasificador bayesiano obtiene en la fase de aprendizaje unos centros casi idénticos a los obtenidos con el método de agrupamiento difuso, por lo que la diferencia fundamental se encuentra en la fase de clasificación, mientras el algoritmo Fuzzy utiliza el grado de pertenencia de cada píxel en la imagen a clasificar a partir de la distancia euclídea, en el de Bayes se emplea la distancia de Mahalanobis. Esto se traduce en que las imágenes presentan los bordes más distorsionados, con sombras y zonas entre clases mezcladas y mayor sensibilidad. Aunque el fuego se identifica correctamente en todos los casos, hay circunstancias en las que se producen falsas etiquetaciones, presentando como fuego objetos que son similares a éste y en realidad no lo son, debido principalmente a esta mayor sensibilidad del método. Es necesario conseguir una buena separabilidad entre clases.

El AGL utiliza un método diferente para la obtención de las clases en el aprendizaje y como tal produce centros diferentes, aunque sin grandes variaciones. Presenta diferencias con respecto a los otros métodos, en las clases con mayor presencia en las imágenes, que tienen más matices y variabilidad, y el fuego según las circunstancias de los elementos circundantes, se identifica ligeramente mejor.

El método SOM también realiza una fase de aprendizaje diferente, obteniendo centros de las clases sensiblemente distintos. Produce resultados similares a los otros métodos, con algo menos de precisión, que se muestra claramente en el caso de fuego sólido de pequeña intensidad, que no es capaz de detectar.

En la tabla 1 se resumen los resultados obtenidos por comparación entre los métodos de clasificación.

Tabla 1: Resumen resultado de los métodos de clasificación según el tipo de fuego.

	Fuego de Gas	Fuego de Líquido	Fuego de Sólido
Fuzzy K-means	Fuego etiquetado correcto. Sin falsas identificaciones.	Difícil con llama pequeña. Sin falsas identificaciones.	Difícil con llama pequeña. Leve falsa identificación.
C. Bayesiano	Fuego etiquetado correcto. Áreas / puntos difuminados	Fuego etiquetado correcto. Falsas identificaciones	Difícil con llama pequeña. Falsas identificaciones
AGL	Difícil con llama pequeña. Sin falsas identificaciones	Difícil con llama pequeña. Sin falsas identificaciones.	Fuego casi correcto. Sin falsas identificaciones.
SOM	Fuego etiquetado correcto. Sin falsas identificaciones.	Difícil con llama pequeña. Sin falsas identificaciones.	Nulo con llama pequeña. Leve falsa identificación.

Como extensión al estudio anterior, intentamos identificar imágenes con fuegos de distinto tipo, como por ejemplo realizar el aprendizaje sobre un fuego de gas, con sus correspondientes muestras e intentar clasificar una imagen de fuego líquido.


Por ejemplo con las imágenes de FG CV 01 y FG CV 02 de la figura 29, se realiza el aprendizaje y sobre la imagen FL CD 04 se intenta identificar el fuego, figura 74.



FL CV 04




Fuzzy FL CV 04



Bayes FL CV 04



Lloyd FL CV 04



SOM FL CV 04

Figura 74: Comparación entre los diferentes métodos aplicados sobre la imagen FL CV 04.

En este caso se comprueba la validez de los métodos, etiquetando el fuego adecuadamente y comprobando las diferencias entre ellos. Se producen buenos resultados en general, muy similares en el caso de Fuzzy y Lloyd, con diferencias en las clases del entorno, no del fuego; mayor sensibilidad y contornos menos definidos en el caso de Bayes; e identificación menos precisa en el caso de SOM.

Como conclusión final a los métodos de clasificación se vuelve a insistir que son adecuados como métodos de detección de incendios, pero es necesario un proceso de aprendizaje minucioso, en el que queden muy bien definidas las clases y puntos a identificar, con un riguroso estudio previo en el que no se presenten elementos que distorsionen el entorno o confundan al evaluar y en el que el fuego contraste claramente con el resto de componentes de la escena.

4.4. Análisis de movimiento.

El último método para la detección de incendios que se analiza, realiza un enfoque totalmente diferente a los empleados hasta ahora. Si anteriormente nos interesábamos por las características de las imágenes en sí, como la intensidad luminosa o el patrón de color que presentaba, en esta ocasión el estudio se centra en la detección de cambios en la escena.

Los procesos de combustión, como se ha podido comprobar a lo largo de este TFM, se manifiestan a través de fenómenos físicos y químicos como la llama visible, la radiación emitida o el humo generado, que lógicamente se encuentran en movimiento y en un estado de variación continua.

Este movimiento es susceptible de ser tratado analíticamente por medio de métodos de visión computarizada, analizando imágenes en forma de secuencia de un mismo escenario estático y comprobando los cambios que se producen entre ellas.

El planteamiento aparentemente sencillo que se ha hecho, encuentra graves inconvenientes por causa principalmente de dos motivos: la necesidad de que los cambios en el escenario sean debidos únicamente al movimiento del fuego y por lo tanto que no existan otros elementos variables que dan lugar a detecciones erróneas; y que la cámara o dispositivo de captura se encuentre perfectamente estable y sin vibraciones, pues distorsionaría notablemente los resultados.

Las dificultades comentadas limitan considerablemente las circunstancias y situaciones en las que se pueden utilizar estos métodos, pero su sencillez les permite seguir siendo válidos en otros muchos entornos con las precauciones y medidas oportunas.

4.4.1. Método de Lucas-Kanade.

El método propuesto para el análisis del movimiento es el denominado de Lucas – Kanade (Lucas y Kanade, 1981), consistente en calcular las variaciones de intensidad de los píxeles de la imagen, suponiendo que éstas son debidas a los cambios en la imagen sobre un escenario fijo. Este cálculo se realiza por medio de un algoritmo que evalúa el gradiente del flujo óptico, de forma análoga a la ecuación de continuidad de los fluidos.

Continuando con los planteamientos realizados hasta ahora en los otros métodos, se utilizarán las mismas imágenes en el entorno estudiado, para los diferentes tipos de fuego: fuego de gas, fuego de líquido y fuego de sólido. En esta ocasión se emplean secuencias de imágenes para comprobar los cambios que se producen entre ellas, debido a los procesos de combustión.

Se analizan por un lado las imágenes capturadas con la CT, y por otro lado las imágenes capturadas con la CV, con el fin de comparar la eficacia de ambos dispositivos en la detección de movimiento. Las imágenes CV es necesario convertirlas a escala de grises.

La imagen resultante se denomina LK - (tipo fuego) – (tipo cámara) – (imágenes comparadas).

Fuego de gas. Cámara en el visible (CV).

Se comparan las imágenes FG CV 01 y FG CV 04, figura 75, convertidas a escalas de grises.

Y el resultado de aplicar el algoritmo se presenta en la figura 76, donde las flechas indican los cambios en el campo de velocidades.



FG CV 01eg



FG CV 02eg

Figura 75: Secuencia de imágenes de fuego de gas con CV en escala de grises.

Dentro del círculo rojo se encuentra el campo de velocidades, correspondiente al cambio de intensidades del fuego capturado por la cámara. Es de difícil visualización e identificación, ya que en el resto de la figura 76, aparecen vectores debidos al movimiento de los elementos del entorno como las nubes y a las oscilaciones de la propia cámara en sí.




Figura 76: Resultado de aplicar el método LK, a las imágenes FG CV 01 y FG CV 02. Imagen LK FG CV 12.

Aparentemente son cambios mínimos en la imagen, pero la sensibilidad del método no distingue unos de otros.

Fuego de gas. Cámara térmica (CT).

Se procede a comprobar los resultados de este método sobre imágenes capturadas por la cámara térmica. Las imágenes a comparar son FG CT 03 y FG CT 04, figura 77.



FG CT 03



FG CT 04

Figura 77: Secuencia de imágenes de fuego de gas con CT.

El resultado en esta ocasión en la imagen siguiente, figura 78.




Figura 78: Resultado de aplicar el método LK, a las imágenes FG CT 03 y FG CT 04. Imagen LK FG CT 34.

Puesto que la CT trabaja con la intensidad debida a la temperatura de los elementos, el contraste es mucho mayor y la representación es magnificada, pequeños cambios suponen grandes variaciones.

Fuego de líquido. Cámara en el visible (CV).

Aplicando el método de LK en el escenario de fuego líquido, se comprueba sobre las imágenes FL CV 02 y FL CV 03, figura 79.



FL CV 02eg



FL CV 03eg

Figura 79: Secuencia de imágenes de fuego de líquido con CV en escala de grises.

La imagen resultante del campo de velocidades es, LK FL CV 23, figura 80.




Figura 80 Resultado de aplicar el método LK, a las imágenes FL CV 02 y FL CV 03. Imagen LK FL CV 23.


De nuevo los elementos del entorno, como el humo en este caso, y las oscilaciones de la cámara provocan una imagen en la que es muy difícil distinguir el movimiento del fuego de la escena.

Fuego de líquido. Cámara térmica (CT).

Comprobamos ahora este escenario con imágenes capturadas con la CT. FL CT 02 y FL CT 04, figura 81.



FL CT 02



FL CT 04

Figura 81: Secuencia de imágenes de fuego de líquido con CT.

La imagen obtenida es la LK FL CT 24, figura 82.

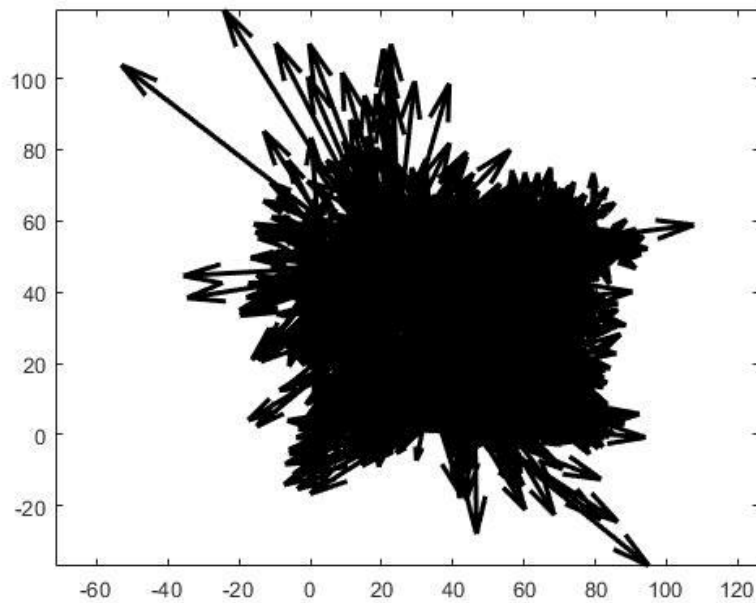


Figura 82: Resultado de aplicar el método LK, a las imágenes FL CT 02 y FL CT 04. Imagen LK FL CT 24.

Los bruscos cambios de intensidad en el movimiento del humo, producen esta imagen, en la que no se puede identificar claramente ni el fuego ni el humo.

Fuego de sólido. Cámara en el visible (CV).

Las imágenes en el espectro visible, convertidas a escala de grises, para el fuego de sólido son FS CV 04 y FS CV 05, figura 83.



FS CV 04eg



FS CV 05eg

Figura 83: Secuencia de imágenes de fuego de sólido con CV en escala de grises.

La aplicación del algoritmo LK, genera la imagen LK FS CV 45, figura 84.





Figura 84: Resultado de aplicar el método LK, a las imágenes FS CV 04 y FS CV 05. Imagen LK FS CV 45.


En esta ocasión, la menor presencia de humo y llamas, y menores oscilaciones de la cámara, producen una imagen más aceptable, en la que se puede observar el desplazamiento vertical del humo.

Fuego de sólido. Cámara térmica (CT).

Verificamos la aplicación sobre imágenes capturadas con la CT, FS CT 01 y FS CT 04, figura 85.



FS CT 01



FS CT 04

Figura 85: Secuencia de imágenes de fuego de sólido con CT.

Se genera la imagen LK FS CT 14, figura 86.




Figura 86: Resultado de aplicar el método LK, a las imágenes FS CT 01 y FS CT 04. Imagen LK FS CT 14.

En la figura 86 se muestra un resultado en el que se presentan variaciones importantes en el flujo óptico y el campo vectorial con elementos muy marcados, debido al fuerte contraste entre los elementos a alta temperatura y el fondo.

4.4.2. Mejoras y alternativas en la detección de movimiento.

Fuego de sólido. Cámara en el visible (CV). Segunda parte.

Debido a la fuerte dependencia del entorno y las condiciones para la aplicabilidad de este método, se ha procedido a realizar una serie de capturas para las imágenes en un nuevo escenario controlado.



FS2 CV 04eg



FS2 CV 05eg

Figura 87: Secuencia de imágenes de fuego de sólido con CV en escala de grises.

En esta ocasión, se procede a la combustión de unas hojas de papel, en una terraza, evitando interferencias con el aire del entorno. Se intenta que no se produzcan vibraciones de la cámara CV y no aparezcan elementos móviles no deseados en la escena.

De este modo las imágenes son ahora, FS2 CV 04eg y FS2 CV 05eg, figura 87.

En las imágenes de la figura 87 apenas hay llama y el cambio en la intensidad de los píxeles de la escena se debe al movimiento del humo del fuego.

El método produce ahora como resultado, LK FS2 CV 45, figura 88. En dicha imagen, se enmarcan en rojo las variaciones más pronunciadas en el campo vectorial representado. Estas variaciones corresponden, como se ha indicado al movimiento del humo, que modifica la intensidad de los píxeles, en esa área.

Continúan identificándose como leves movimientos ciertas zonas de la imagen que se encuentran estáticas, aunque se ha minimizado este fenómeno con respecto a los otros escenarios estudiados.




Figura 88: Resultado de aplicar el método LK, a las imágenes FS2 CV 04 y FS2 CV 05. Imagen LK FS2 CV 45.

Combinación de métodos de reconocimiento de patrones y detección de movimiento.

Con el fin de proponer mejoras en la aplicabilidad de los métodos estudiados, se procede a combinar algunos de ellos con el fin de minimizar sus inconvenientes y mantener sus ventajas. Se ha visto claramente que dependiendo del tipo de fuego y escenario, o del método elegido, los resultados han sido más o menos satisfactorios, dependiendo de la sensibilidad, el entorno y las condiciones climáticas.

De este modo, se escogen las imágenes FL CV 02 y FL CV 03, figura 89, y aplicamos el método de reconocimiento de patrones de Fuzzy, con el fin de localizar el fuego en las imágenes.




FL CV 02




FL CV 03

Figura 89: Imágenes de fuego líquido.

De este modo obtenemos de nuevo las siguientes imágenes Fuzzy FL CV 02 y Fuzzy FL CV 03, figura 90.



Fuzzy FL CV 02



Fuzzy FL CV 03

Figura 90: Imágenes de fuego líquido.

Puesto que en estas imágenes hay zonas que se han etiquetado como fuego, se puede aplicar el método de LK, para comprobar que hay movimiento en las mismas. Para ello se recorta la imagen, centrándonos en las partes etiquetadas como fuego, con lo que se simplifica el análisis y limitamos los puntos susceptibles en los que detectar cambios.

De este modo, convertimos a escala de grises y se recortan las imágenes, obteniendo la figura 91.




Figura 91: Imágenes de fuego líquido.

Si ahora se aplica el método LK, se obtiene la imagen de la figura 92, imagen LK FL 23r. Al haber reducido el campo de análisis para la detección de movimiento, centrándonos en la zona etiquetada como tal, en el proceso previo de clasificación, se ha mejorado notablemente el resultado.

Como se puede observar se aprecia el movimiento de la llama y el humo, representando el campo vectorial correspondiente al flujo óptico, es decir las variaciones de intensidad de los píxeles.




Figura 92: Imagen LK FL 23 r, resultante de aplicar sobre imágenes clasificadas y reducidas.

De esta forma, al combinar métodos, se elimina la posibilidad de identificar erróneamente objetos estáticos que presenten similitudes con la clase etiquetada como fuego.

Diferencia de la matriz de intensidades y reconocimiento de patrones.

Con el fin de probar otras alternativas en la detección de cambios en las imágenes con fuego, en esta ocasión se va a proceder de forma inversa a la realizada en el apartado anterior. Se analizan los cambios y luego se intenta etiquetar el fuego en la imagen resultante.

El método de diferencias para la detección de movimiento, en su forma más sencilla, simplemente restando las matrices que almacenan los valores RGB de una imagen, produce una nueva imagen en la que se identifica el fuego con los clasificadores ya estudiados.

Para comparar resultados, de nuevo se utilizan las imágenes FL CV 02 y FL CV 03, figura 89. Se restan, como se ha comentado, la matriz RGB que las representa y se calcula el valor absoluto de la diferencia. Así obtenemos la imagen Dif FL CV 23, figura 93.



Figura 93: Imagen Dif FL CV 23, resultante de aplicar el método de diferencias.

La aplicación de los métodos conocidos de clasificación, y el proceso de aprendizaje correspondiente, nos llevan a obtener una clasificación, como la mostrada en la figura 94.

Se puede comprobar que coherentemente los métodos etiquetan la mayor parte como el fondo negro, pero aparecen zonas de fuego que se han identificado, especialmente el algoritmo de Bayes (superior derecho) que etiqueta toda la zona de llama como tal.




Figura 94: Imagen con la clasificación de la imagen Dif FL CV 23, según los métodos de Fuzzy, Bayes, AGL y SOM.

CAPÍTULO 5. CONCLUSIONES Y LÍNEAS FUTURAS.

Una vez examinados los métodos utilizados en visión artificial con el fin de detectar la presencia de fuego en un escenario concreto, se puede concluir que dichos métodos son perfectamente válidos y aplicables para dicha tarea, aunque es necesario tener en cuenta una serie de consideraciones al respecto.

El planteamiento realizado ha sido sobre distintos tipos de fuego, en un entorno controlado y estático. Para poder tener unos resultados adecuados es necesario por lo tanto hacer un estudio previo en el que se tengan en cuenta los procesos de combustión, dependientes del tipo de combustible y que generarán productos como el humo o gases que pueden interferir en nuestro análisis. Del mismo modo, es necesario tener en cuenta todos los elementos que puedan aparecer en la escena y provocar identificaciones equivocadas.

El método de multiumbralización de Otsu, aplicado sobre imágenes capturadas con cámara térmica, puede ser válido, pero presenta el inconveniente de que se desconoce a priori el número de umbrales y por lo tanto regiones a considerar para poder hacer una identificación correcta. Un número en exceso o por defecto de ellos, provocaría que no se etiqueten las zonas de fuego como tal o que se etiqueten las que no son. Es importante tener en cuenta que al ser una imagen térmica debe presentar el fuego una zona relativamente amplia y con contraste elevado con el resto de la escena para destacarlo convenientemente.

Como ventaja del método de Otsu, destaca su capacidad de detectar elementos a elevada temperatura (y/o muy bajas temperaturas también) como conductos, humos o superficies no necesariamente con llama visible. Este hecho es un factor muy importante a considerar en la evolución de un incendio, para prevenir y valorar las intervenciones.

La detección de superficies calientes y elementos a alta temperatura, puede tener numerosas aplicaciones en procesos industriales en los que es necesario realizar un control o supervisión continuo de los mismos.

El reconocimiento de patrones, necesita de una minuciosa fase de aprendizaje en la que los posibles riesgos a identificar, se determinen muy claramente en dicha fase. La clase correspondiente al fuego debe estar muy bien definida y contrastar suficientemente con el resto de las clases para evitar luego clasificaciones erróneas. Por todo ello la selección de muestras debe ser adecuada y generar unos centros de las clases que sean representativos de los patrones presentes en el escenario. En general para los fuegos de gases los resultados han sido los más satisfactorios, ya que por sus circunstancias se diferencia mejor del entorno.

Con respecto a los métodos en sí de clasificación, aun no existiendo grandes diferencias entre los centros calculados por ellos, a la hora de clasificar pueden dar lugar a resultados dispares, ello es debido a la amplia variedad de matices y tonalidades presentes en cada

patrón. Como apunte cabe recordar que hemos partido siempre de un número de clases establecido, cuatro, no siendo siempre posible esa estimación o no siendo la mejor opción.

El algoritmo Fuzzy K-means, ha sido probado con resultados aceptables en todos los escenarios. Identifica correctamente el fuego, incluso para llamas muy pequeñas y no genera falsas detecciones.

El algoritmo clasificador bayesiano ha sido el que presenta resultados más distintos entre los diferentes métodos de clasificación. Tiene una mayor sensibilidad a las variaciones, pero esto le hace etiquetar mal algunos elementos presentes y tener menor homogenización en las zonas clasificadas.

El algoritmo generalizado de Lloyd, produce centros distintos para las clases a los anteriores y aunque con llamas de gas pequeñas tiene peor resultado, para fuegos sólidos con humo y restos quemados es más eficaz. No produce generalmente falsas identificaciones.

El algoritmo de SOM con gases es correcto pero obtiene peor resultado en fuegos sólidos y presenta algunos puntos mal clasificados.

Los métodos de detección de movimiento necesitan de unas condiciones muy precisas para ser válidos, pues ligeras variaciones en la captura de imágenes distorsionan los resultados. De este modo es preciso tener en cuenta el ambiente, si es exterior o interior, la estabilidad de la cámara o la iluminación de la escena.

Con la cámara térmica el flujo óptico refleja los cambios muy exageradamente, debido al contraste entre las superficies y elementos a alta temperatura y los que no lo están. Con la cámara operando en el espectro visible, los resultados dependen mucho del fondo e iluminación de la imagen.

Como mejora se ha evaluado la combinación de métodos de clasificación y detección de movimiento, con resultado satisfactorio, pues se limita el área de estudio a la zona clasificada, etiquetando más precisamente el fuego y con menor probabilidad de error.

Como posibles líneas futuras de actuación o investigación en las que continuar en esta materia, se encontrarían:

- Para mejorar los resultados de multiumbralización se podrían emplear métodos de estimación automática del número de umbrales (Díaz, 2017) aplicados sobre las imágenes térmicas de incendios, con el fin de minimizar este inconveniente.
- En lugar de establecer de antemano un número de clases establecido, como ha sido el caso, puede ser necesario en otras ocasiones calcular el número de clases existentes. Para ello existen algoritmos que realizan esta tarea desde otro enfoque, como el algoritmo de cuantización vectorial.
- Existen numerosos algoritmos de reconocimiento que no se ha aplicado en este estudio y que tendrían validez tales como el perceptrón o las redes neuronales, donde las redes convolucionales en el ámbito de lo que se conoce como

aprendizaje profundo (deep learning) están llamadas a jugar un papel relevante (Davis, 2018) y más clásicos pero eficientes como las conocidas como Máquinas de Vectores Soporte (SVM, Support Vector Machines) (Vega y Dormido-Canto, 2010).

- Para mejorar las imágenes capturadas y llegar a resultados óptimos, sería interesante considerar la posibilidad de realizar operaciones de mejora de imagen tales como suavizado y realzado (Pajares y Cruz, 2007).
- En cuanto a la detección de movimiento otras técnicas aplicables serían el análisis de movimiento basado en puntos de interés donde el método SURF (Speeded-Up Robust Features) descrito en Bay y col. (2008) se perfila como un buen candidato, el método diferencial o el modelo de diferencias respecto al fondo (estudiado brevemente).
- La combinación de diferentes métodos y técnicas permite minimizar las desventajas que presentan y mantener sus virtudes. Ello repercute en la calidad de la detección y la reducción de posibles errores. Ejemplo de este punto es el análisis efectuado en este trabajo en el punto 4.4.2.

BIBLIOGRAFÍA.

- Ballard, D.H., Brown, C.M. (1982). *Computer Vision*. Prentice-Hall, Englewood Cliffs: NJ.
- Bay, H., Ess, A., Tuytelaars, T., van Gool, L. (2008). SURF: Speeded Up Robust Features. *Computer Vision and Image Understanding*, 110(3), 346–359.
- Davis, E.R. (2018). *Computer Vision: principles, algorithms, applications, learning*. Academic Press, London, UK.
- Díaz Fernández, M. (2017). Segmentación de imágenes térmicas mediante métodos de umbralización automáticos. TFM Máster en Ingeniería de Sistemas y Control. UNED – UCM.
- DMC-TZ20 (2018) Cámara digital compacta Panasonic DMC-TZ20. Disponible on-line: http://www.panasonic-la.com/avc/lumix/compact/zs10_tz20/index.html (visitado última vez agosto 2018).
- Duda, R. O., Hart, P. E., Stork, D. G. (2001). *Pattern Classification*. John Wiley & Sons, New York, U.S.
- Hitado, P. A. (2015). Manual de Incendios. V6.00. Parte 1. Teoría del fuego. Formación para bomberos. CEIS Guadalajara. Disponible on-line: http://ceis.antiun.net/docus/pdfsonline/m1/M1_Incendios_v6_01_teoríaFuego/mobil_e/index.html#p=1 (visitado última vez septiembre 2018).
- Jensen J. R., (1982) *Introductory Digital Image Processing*. Prentice-Hall, Englewood Cliffs, NJ.
- Linde, Y., Buzo, A., Gray, R.M. (1980). An algorithm for Vector Quantization Design. *IEEE Trans. Communications*, 28(1), 84-95.
- Lloyd, S.P. (1957). Least squares quantization in PCM's, *Bell Telephone Laboratories Paper*, Murray Hill, NJ.
- Lucas, B.D., Kanade, T. (1981). An iterative image registration technique with an application to stereovision, *Proc. 7th Conf. On Artificial Intell*, Vancouver (CA) pp. 674-679.
- Matlab R2017b. Mathworks, Inc. TM. Disponible on-line: <https://es.mathworks.com/> (visitado por última vez agosto 2018).
- Nalwa, V.S. (1993) *A Guided tour of Computer Vision*. Addison-Wesley, Reading: MA.

BIBLIOGRAFÍA.

- Nomura, A., H. Miike, K. Koga (1994). Detecting a velocity field from sequential images under time-varying illumination, pp 343-350. In Time-Varying Image Processing and Moving Object Recognition vol. 3. V. Capellini (Ed.) Elsevier, Amsterdam.
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. IEEE Trans. System Man and Cybernetics. SMC-9, 62-66.
- Pajares G., Cruz J.M. (2007). *Ejercicios resueltos de Visión por Computador*. Ed. RA-MA, Madrid.
- Pajares G., Cruz J.M. (2007). *Visión por computador: Imágenes digitales y aplicaciones* (2º ed.) RA-MA, Madrid.
- Pinilla, C. (1995). Elementos de teledetección, RA-MA, Madrid.
- Sonka, M., Hlavac, V, Boyle, R. (1995). Image Processing, Analysis and Machine Vision, Chapman-Hall, Cambridge.
- UCF 6000 (2018) Cámara térmica Dräger UCF 6000. Disponible on-line: https://www.draeger.com/es_es/Applications/Products/Personal-Protection-Equipment/Thermal-Imaging-Cameras/UCF-6000 (visitado última vez agosto 2018).
- UNE 13943 (2012). Seguridad contra incendios. Vocabulario. UNE-EN ISO 13943:2012. Disponible on-line: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma/?Tipo=N&c=N0049712> (visitado última vez septiembre 2018).
- UNE-EN 2 (1994). Clases de Fuego. UNE-EN 2:1994. Disponible on-line: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma/?c=N0008346> (visitado última vez septiembre 2018).
- Vega, J. A., Dormido-Canto, S. (2010). Máquinas de Vectores Soporte. Aprendizaje Automático (Pajares, G. y de la Cruz, J.,M., Eds.). RA-MA, Madrid

ANEXOS.

ANEXO A. Equipos utilizados.

CÁMARA TÉRMICA DRÄEGER UCF 6000. CARACTERÍSTICAS TÉCNICAS.

Tabla 2: Características técnicas de la cámara térmica.

Dimensiones de la cámara	(An. x Al. x F.) 125 x 280 x 110 mm
Peso	1,4 kg, incluida la batería
Pantalla	
Tecnología	Pantalla de cristal líquido (LCD)
Tamaño (diagonal)	9 cm
Carcasa	
Cubierta protectora	Material de caucho EPDM
Correas de transporte	Material resistente a las altas temperaturas
Material de la carcasa	Plástico resistente a altas temperaturas
Clase de protección	IP 67
Especificaciones de infrarrojos	
Tipo de sensor	Matriz microbolométrica a-Si
Resolución	160 x 120 píxeles
IR espectral	De 7 a 14 μm
Sensibilidad de temperatura	Nominal 0,035 °C
Frecuencia de imagen	50 Hz
Óptica	
Material	Germanio
Foco	De 1 m a infinito
Campo de visión	Horizontal: 47° / Vertical: 32° / Diagonal 62°
Funcionamiento	
Tiempo de funcionamiento (a 23°C) con batería	Nominal de 4 horas
Tiempo de func. (a 23 °C) con pilas alcalinas	Nominal de 2 horas
Medición de temperatura	Visor digital de temperatura: -40 °C ... 1,000 °C
Temperatura de funcionamiento	-40 °C ... 85 °C
Tecnología de la batería	Baterías recargables de iones de litio
Indicador del estado de la batería	Indicador preciso de 4 niveles de carga

CÁMARA DIGITAL PANASONIC DMC-TZ20. CARACTERÍSTICAS TÉCNICAS.

Tabla 3: Características técnicas de la cámara digital compacta operando en el espectro visible.

Captura de imagen	
Procesador	Venus Engine FHD
Tipo de sensor	MOS
Tamaño del sensor	1/2.33"
Relación de aspecto	4:3
Resolución sensor	14.0 MP
Píxeles efectivos	4320x3240
Otras resoluciones	3648x2736, 3072x2304, 4320x2880 (3:2),

ANEXOS.

	4320x2432 (16:9), 3232x3232 (1:1).
Formato JPEG	JPEG 2.21 , 2 calidades
Otros Formatos	3D MPO
Captura de video	Full HD, con audio estéreo
Formato de video	QuickTime (Motion JPEG), AVCHD
Resolución de video	AVCHD: 1920x1080 60i, 1280x720 60p
Sistema óptico	
Distancia focal	24-384 mm. (real: 4.3 - 68.8 mm.)
Zoom óptico	16x
Zoom digital	4x
Tipo de objetivo	Leica DC Vario-Elmar, 12 elementos en 8 grupos, 3 lentes esféricas y 1 ED.
Estabilizador	sí: Power OIS (óptico)
Aberturas	F:3.3 - F:6.3 (angular), F:5.9 - F:6.3 (tele).
Adaptador de accesorios	no
Rango de enfoque	50 cm. a infinito
Enfoque en macro	3 cm.
Enfoque manual	no
Enfoque automático	sí
Luz de ayuda	sí
Tipo de enfoque	puntual - 1 zona - 23 zonas - a caras - táctil
Modos de enfoque	normal, macro, rápido, continuo, seguimiento AF
Control de exposición	
Rango de ISO	100-1600, auto, modo alta sensibilidad auto: 1600-6400.
Tipo de obturador	mecánico/electrónico
Velocidad de obturación	1/4000 a 8 seg., 15, 30 o 60 seg. en modo especial.
Comp. de exposición	-2 a +2 EV en pasos de 1/3 EV
Medición de exposición	Inteligente (matricial), Central promediado, Puntual
Balance de blanco	Auto, 4 presets con ajuste fino, manual
Control de disparo	
Modos de exposición	AE Programado, Prioridad a la abertura, Prioridad al obturador, Manual.
Modos de escena	sí, 29 modos
Bracketing	3 tomas, de 1/3 a 1 EV
Disparo continuo	10 ips (max. 15 imágenes)
Temporizador	2 o 10 seg.
Control remoto	no
Características físicas	
Resiste al agua	no
Alimentación	batería de Litio, incluida: 3,6V, 895mAh.
Duración batería	foto: 260 disparos
Datos del cuerpo	Metal, pantalla táctil y GPS.
Otras características	sensor de orientación
Dimensiones	104.9 x 57.6 x 33.4 mm., (volumen: 202 cc.).
Peso	219. (con tarjeta y batería)

ANEXO B. Muestras en los métodos de aprendizaje.

En los procesos de aprendizaje y clasificación, es necesario seleccionar una serie de muestras con el ratón sobre las imágenes que sirven de patrón. Para cada tipo de fuego: gas, líquido y sólido, se escogen dos imágenes características y sobre cada una de ellas se seleccionan los 50 valores.

Las siguientes tablas recogen los valores [R, G, B] desde 0 a 255 incluidos, para cada tipo de fuego, almacenados en la variable X1 respectivamente.

Fuego de gas.

Tabla 4: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de gas.

Nº	R	G	B
1	197	215	229
2	192	211	228
3	194	215	234
4	215	233	247
5	237	246	255
6	160	178	200
7	192	209	225
8	191	214	228
9	216	234	248
10	148	174	197
11	18	23	16
12	44	54	29
13	58	73	42
14	35	43	32
15	21	33	21
16	17	29	15
17	17	31	6
18	22	38	9
19	119	125	53
20	8	25	0
21	142	142	142
22	134	135	130
23	153	153	151
24	149	150	152

Nº	R	G	B
51	198	214	230
52	191	210	227
53	193	214	233
54	207	224	240
55	204	221	237
56	150	168	192
57	190	207	225
58	177	203	226
59	163	188	210
60	152	176	200
61	18	26	15
62	42	45	34
63	59	70	40
64	18	23	19
65	46	55	34
66	4	18	1
67	30	43	15
68	16	25	4
69	15	34	4
70	18	31	13
71	140	140	140
72	154	155	149
73	150	152	147
74	156	157	159

Nº	R	G	B
25	145	150	153
26	144	143	141
27	146	148	145
28	134	138	139
29	135	139	138
30	148	148	148
31	214	136	64
32	120	71	28
33	186	119	32
34	245	183	96
35	167	98	41
36	220	150	78
37	206	128	53
38	225	153	79
39	145	93	43
40	201	140	51
41	138	138	136
42	133	135	134
43	135	139	140
44	130	132	131
45	131	132	134
46	10	11	13
47	19	23	24
48	18	26	29
49	13	14	18
50	25	30	33

Nº	R	G	B
75	142	146	149
76	144	143	139
77	145	145	143
78	137	139	138
79	142	143	145
80	132	134	133
81	188	118	49
82	186	107	40
83	191	132	64
84	187	115	43
85	242	170	86
86	255	211	116
87	253	219	122
88	205	139	45
89	254	217	128
90	235	164	74
91	133	84	41
92	120	83	41
93	255	211	115
94	250	204	108
95	255	227	130
96	222	236	249
97	178	208	232
98	189	208	225
99	188	205	225
100	175	192	212

Fuego de líquido.

Tabla 5: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de líquido.

Nº	R	G	B
1	141	138	123
2	145	142	127

Nº	R	G	B
51	190	189	185
52	190	189	184

ANEXOS.

Nº	R	G	B
3	132	126	110
4	151	148	129
5	130	124	108
6	154	149	129
7	119	115	104
8	155	150	130
9	102	99	90
10	107	105	93
11	183	195	195
12	136	147	143
13	186	196	197
14	149	158	155
15	160	175	178
16	153	162	159
17	181	196	201
18	165	175	176
19	182	197	202
20	177	191	192
21	115	111	84
22	125	120	88
23	113	111	96
24	108	107	89
25	96	96	60
26	103	103	75
27	104	101	92
28	135	135	111
29	96	96	72
30	101	101	73
31	246	184	143
32	189	157	144
33	159	67	30
34	237	134	55
35	224	148	99
36	208	153	122
37	206	164	140
38	204	95	26

Nº	R	G	B
53	198	195	190
54	196	196	188
55	195	192	183
56	159	157	142
57	149	143	127
58	140	134	118
59	122	119	104
60	156	150	134
61	186	200	201
62	192	203	205
63	186	201	206
64	184	198	201
65	180	195	200
66	175	189	190
67	165	175	176
68	154	165	167
69	170	180	179
70	176	184	186
71	122	118	93
72	114	115	75
73	121	119	106
74	116	113	94
75	96	96	68
76	128	129	98
77	114	113	83
78	106	105	84
79	105	107	67
80	87	88	56
81	255	233	153
82	216	111	46
83	197	97	47
84	191	93	48
85	248	161	66
86	254	177	85
87	251	228	160
88	243	164	69

ANEXOS.

Nº	R	G	B
39	226	152	79
40	198	137	108
41	46	42	43
42	41	36	33
43	40	39	37
44	26	30	31
45	25	29	30
46	212	101	30
47	255	156	59
48	186	132	86
49	222	158	122
50	208	126	76

Nº	R	G	B
89	246	182	95
90	249	158	67
91	213	144	66
92	244	149	69
93	210	122	58
94	252	148	63
95	255	168	71
96	51	49	52
97	38	36	37
98	26	30	31
99	25	29	30
100	34	32	33

Fuego de sólido.

Tabla 6: Muestras seleccionadas en imágenes correspondientes al escenario de fuego de sólido.

Nº	R	G	B
1	129	126	111
2	119	115	103
3	162	159	144
4	150	147	130
5	128	122	108
6	154	148	132
7	139	133	121
8	150	145	126
9	125	118	108
10	150	143	125
11	176	190	191
12	177	191	194
13	140	149	148
14	170	184	187
15	176	188	188
16	178	193	196

Nº	R	G	B
51	149	147	134
52	163	160	145
53	150	146	134
54	132	126	114
55	91	83	72
56	132	128	116
57	122	123	109
58	139	133	117
59	94	90	79
60	112	108	96
61	185	196	198
62	149	159	158
63	177	187	186
64	173	183	184
65	168	178	177
66	167	182	187

ANEXOS.

Nº	R	G	B
17	183	194	196
18	178	192	195
19	142	153	155
20	166	180	183
21	82	77	58
22	122	115	99
23	99	98	80
24	100	99	81
25	81	82	66
26	85	87	66
27	82	78	67
28	98	94	82
29	142	143	137
30	81	81	53
31	183	100	58
32	139	66	31
33	180	121	77
34	137	119	107
35	187	156	136
36	131	123	120
37	243	185	139
38	203	158	137
39	226	178	142
40	236	186	151
41	33	31	34
42	32	31	29
43	39	37	38
44	64	68	69
45	25	29	28
46	253	150	75
47	164	121	104
48	216	166	131
49	238	184	146
50	210	160	125

Nº	R	G	B
67	167	180	186
68	170	183	189
69	170	185	190
70	155	170	175
71	71	68	51
72	88	88	54
73	103	101	86
74	102	100	88
75	79	76	67
76	82	84	62
77	73	68	46
78	91	88	79
79	87	88	74
80	84	83	63
81	210	161	95
82	255	188	100
83	251	204	116
84	243	214	122
85	255	216	121
86	244	206	123
87	255	218	120
88	224	146	82
89	233	151	91
90	205	123	75
91	44	46	43
92	44	45	40
93	22	22	22
94	43	39	38
95	42	42	34
96	252	165	85
97	255	161	74
98	254	198	111
99	231	163	116
100	215	136	80

ANEXO C. Tablas de validación de las muestras.

Para las clases obtenidas con los métodos de aprendizaje, se verifican las mismas a través de sus parámetros de validación, con los que se comprueba su distribución estadística.

Fuzzy K-means

Para el caso del algoritmo Fuzzy K-means, se obtiene la siguiente tabla de validación:

Tabla 7: Comparativa de los coeficientes de validación para el algoritmo Fuzzy K-means.

	Coeficiente de Partición (CP)	Coeficiente de Entropía (CE)
Fuego de Gas	0'90	0'17
Fuego de Líquido	0'89	0'21
Fuego de Sólido	0'89	0'22

El coeficiente de Partición (CP), que mide el solapamiento entre clases, nos indica que cuanto más próximo a la unidad esté su valor, mejor es la partición de datos. El coeficiente de Entropía (CE), al contrario que el anterior, cuanto más próximo es el valor a 0, mejor es la partición.

En nuestros escenarios y para las muestras seleccionadas, la mejor partición se genera con el fuego de gas, siendo prácticamente iguales los escenarios de líquido y sólido.

Clasificador Bayesiano

Para las clases establecidas y los centros calculados según el clasificador bayesiano, podemos estudiar la validez de la partición.

En este caso resulta una tabla para cada uno de los parámetros con los valores de la Divergencia, Coseno de Alpha y Distancia de Jeffries – Matusita, respectivamente, que miden el grado de separabilidad de las clases y comparados en cada uno de los tipos de fuego.

Las tablas representan las matrices resultantes de comparar y aplicar las definiciones de los coeficientes según se expresan en las ecuaciones 3.20, 3.21 y 3.22, de cada una las clases entre sí.

- Divergencia

Tabla 8: Comparativa de los valores de la divergencia entre clases, para los distintos tipos de fuego.

Fuego de gas		C₁	C₂	C₃	C₄
	C₁	0,00	13,73	8,33	-73,26
	C₂	35,77	0,00	-2,61	-10,50
	C₃	44,45	145,16	0,00	107,94
	C₄	96,71	17,45	-52,81	0,00
Fuego de líquido		C₁	C₂	C₃	C₄
	C₁	0,00	12,60	2,56	-701,99
	C₂	-5,03	0,00	9,19	-387,11
	C₃	-0,66	1,58	0,00	-811,69
	C₄	939,98	496,52	1210,83	0,00
Fuego de sólido		C₁	C₂	C₃	C₄
	C₁	0,00	76,26	438,99	78,08
	C₂	28,45	0,00	20,04	2,90
	C₃	-8,46	6,83	0,00	56,84
	C₄	14,48	1,41	-45,04	0,00

- Coseno del ángulo formado por los vectores media.

Tabla 9: Comparativa de los valores del coseno entre vectores media, para los distintos tipos de fuego.

Fuego de gas		C₁	C₂	C₃	C₄
	C₁	0,00	0,91	1,00	0,97
	C₂	0,91	0,00	0,92	0,95
	C₃	1,00	0,92	0,00	0,97
	C₄	0,97	0,95	0,97	0,00

Fuego de líquido		C₁	C₂	C₃	C₄
	C₁	0,00	1,00	0,92	1,00
	C₂	1,00	0,00	0,95	0,99
	C₃	0,92	0,95	0,00	0,92
	C₄	1,00	0,99	0,92	0,00
Fuego de sólido		C₁	C₂	C₃	C₄
	C₁	0,00	0,99	0,95	0,99
	C₂	0,99	0,00	0,98	1,00
	C₃	0,95	0,98	0,00	0,98
	C₄	0,99	1,00	0,98	0,00

- Distancia de Jeffries - Matusita.

Tabla 10: Comparativa de los valores de la DJM entre clases, para los distintos tipos de fuego.

Fuego de gas		C₁	C₂	C₃	C₄
	C₁	0,00	1,99	1,98	2,00
	C₂	1,99	0,00	2,00	1,98
	C₃	1,98	2,00	0,00	2,00
	C₄	2,00	1,98	2,00	0,00
Fuego de líquido		C₁	C₂	C₃	C₄
	C₁	0,00	1,89	1,95	2,00
	C₂	1,89	0,00	1,99	2,00
	C₃	1,95	1,99	0,00	2,00
	C₄	2,00	2,00	2,00	0,00
Fuego de sólido		C₁	C₂	C₃	C₄
	C₁	0,00	1,90	2,00	2,00

ANEXOS.

	C₂	1,90	0,00	1,95	1,81
	C₃	2,00	1,95	0,00	2,00
	C₄	2,00	1,81	2,00	0,00

La matriz de divergencia presenta los valores más elevados generalmente entre las clases del fuego líquido.

Para el coseno del ángulo entre los vectores media, mayor paralelismo significa mayor similitud entre clases, siendo en este caso los valores más elevados del coseno. Así, los mayores valores se encuentran en el fuego sólido.

Para la DJM, mayor distancia implica mayor separabilidad de las clases.

ANEXO D. Tablas comparativas de los centros de las clases.

Con los valores obtenidos para los centros de las clases, al aplicar los diferentes métodos se realiza la siguiente tabla comparativa, representando los colores y su correspondiente valor RGB.

Tabla 11: Centros obtenidos para las clases según el método de aprendizaje aplicado y el tipo de fuego.

Fuego de gas.

	COLOR			
	C ₁	C ₂	C ₃	C ₄
Fuzzy				
Bayes				
AGL				
SOM				

RGB											
C ₁			C ₂			C ₃			C ₄		
196	213	227	204	139	62	143	145	144	26	35	20
197	212	221	201	143	67	142	145	146	28	36	20
180	200	220	227	169	82	141	141	139	25	34	17
191	210	227	201	133	50	137	139	139	18	27	15

Fuego de líquido.

	COLOR			
	C ₁	C ₂	C ₃	C ₄
Fuzzy				
Bayes				
AGL				
SOM				

RGB											
C ₁			C ₂			C ₃			C ₄		
189	187	181	119	116	94	228	142	70	36	36	36
186	187	179	122	118	96	225	140	71	35	35	35
193	184	178	115	112	86	232	146	69	34	34	35
182	197	201	109	107	90	249	158	66	26	30	31

Fuego de sólido.

	COLOR			
	C ₁	C ₂	C ₃	C ₄
Fuzzy				
Bayes				
AGL				
SOM				

RGB											
C ₁			C ₂			C ₃			C ₄		
172	184	186	140	130	115	237	178	112	70	67	54
171	183	184	140	130	115	235	175	111	72	68	55
162	158	149	113	102	87	239	174	104	57	55	44
170	184	188	150	147	132	250	213	121	42	40	37

