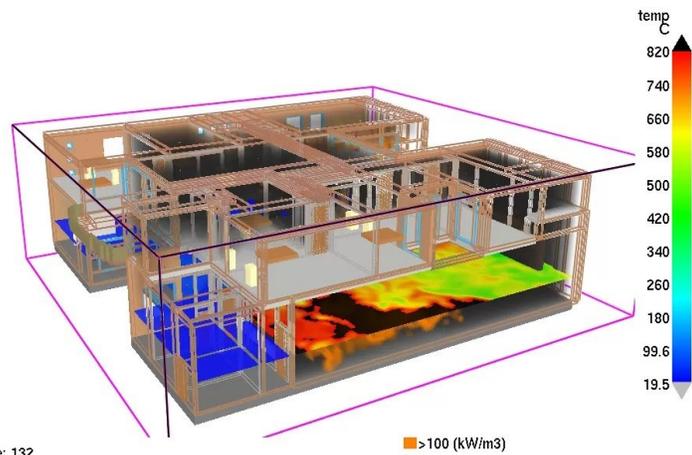
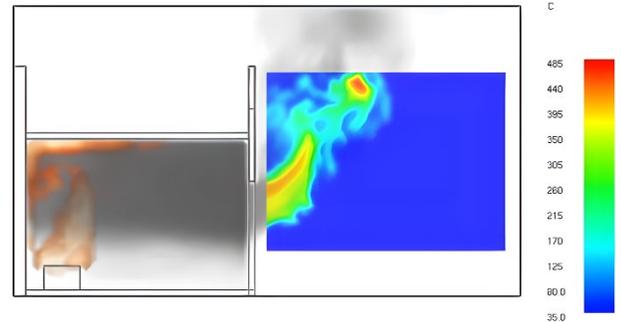




# Modelado y simulación para la predicción de explosiones en espacios confinados

Daniel Cortés Blasc





Universitat d'Alacant  
Universidad de Alicante

Instituto Universitario de Investigación en  
Informática

Escuela Politécnica Superior

# Modelado y simulación para la predicción de explosiones en espacios confinados

Daniel Cortés Blasco



Universitat d'Alacant  
Universidad de Alicante



*Si quieres desvelar los secretos del universo,  
piensa en términos de energía,  
frecuencia y vibración*

**Nicola Tesla**



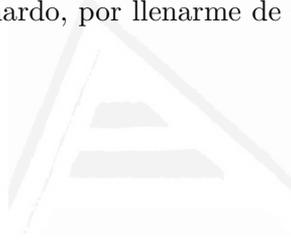
Universitat d'Alacant  
Universidad de Alicante



# Dedicatoria

---

Esta tesis está dedicada a mi mujer Carolina, por su incansable apoyo para poder llevar este trabajo a su fin. Gracias por apostar por mí, navegar por las aguas de la vida a tu lado ha sido la mejor decisión que he tomado. A mi hijo Leonardo, por llenarme de energía cada mañana y ser mi inspiración.



Universitat d'Alacant  
Universidad de Alicante



# Agradecimientos

---

Quiero agradecer a mis directores de tesis, Jorge Azorín y David Gil, todo el tiempo que han dedicado para poder culminar este trabajo. Me habéis enseñado a ver las cosas desde otra perspectiva, a ser más crítico conmigo mismo y sobre todo a aceptar las críticas de los demás como una oportunidad de mejora, un regalo. Me llevo vuestros consejos y parte de vuestra sabiduría y sobre todo dos amigos. El camino no ha sido fácil, sobre todo este último año debido a la pandemia (COVID-19), pero sin duda ha merecido la pena y he disfrutado cada minuto, muchas gracias por todo.

Al Consorcio de Bomberos de Alicante, por cederme las instalaciones para poder realizar la experimentación y facilitarme todo el material necesario.

Alicante, 18 de enero de 2021  
Daniel Cortés Blasco



# Abstract

---

Enclosure fires are a type of emergency involving firefighters whose lives are sometimes put at risk. The emergency team may encounter two types of combustion environments in any confined fire, ventilated or under-ventilated. This scenario's rapid changing behaviour depends on multiple factors such as enclosure size, ventilation or fuel involved, among others. Sometimes, if the right conditions are met, the extremely dangerous phenomena that are the study of this work may appear (flashover and backdraft). However, the difficulty of handling these situations coupled with human error potential, even if there is undivided attention to the task in hand, remains an unresolved challenge for firefighters today. Therefore, there is a huge demand for new techniques and technologies to tackle this life-threatening emergency. Thermal cameras can help prevent this phenomenon in real time using Artificial Neural Networks (ANN) techniques.

The state of the art analysis suggests that there is not enough knowledge (to the best of my knowledge) about the phenomenon of backdraft. For this reason, from this point, the research focuses on the flashover phenomenon.

Due to the complexity of obtaining a database of real cases related to flashover phenomenon, modelling and simulation techniques have been used to carry out this study. In this thesis, I propose two methods to create and validate a synthetic data set. The first method uses images from a computational fluid simulation software (CFD) in order to make a synthetic data set. To validate the synthetic data set, I propose a second method which consists of comparing quantitatively the data obtained with

two real experiments using the Wasserstein Distance (WD).

Finally, to predict the flashover phenomenon, a prediction method is proposed using the synthetic data set. The resulting prediction model is validated using with two small scale real experiments. From the results obtained, it is concluded that it is possible to predict the flashover with the proposed method.



Universitat d'Alacant  
Universidad de Alicante

# Resumen

---

Los incendios en recintos confinados son un tipo de emergencia que involucra a bomberos cuyas vidas a veces se ponen en peligro. En cualquier incendio confinado, el equipo de emergencia puede encontrar dos tipos de ambientes de combustión, ventilados o infra-ventilados. El comportamiento cambiante de este escenario depende de múltiples factores como el tamaño del recinto, la ventilación o el combustible involucrado, entre otros. Sin embargo, la dificultad de manejar este tipo de situaciones junto con el potencial error humano sigue siendo un desafío sin resolver para los bomberos en la actualidad. En ocasiones, si se dan las condiciones adecuadas, pueden aparecer los fenómenos, extremadamente peligrosos, que son estudio de este trabajo (flashover y backdraft). Por lo tanto, existe una gran demanda de nuevas técnicas y tecnologías, así como avances científicos y tecnológicos para abordar este tipo de emergencias que amenazan la vida y puede causar graves daños estructurales. A lo anterior hay que añadir que, la incorporación de cámaras térmicas en los servicios de extinción de incendios y salvamentos supone un gran avance que puede ayudar a prevenir estos tipos de fenómenos en tiempo real utilizando técnicas de inteligencia artificial (AI, *Artificial Intelligence*).

Una vez finalizado el análisis del estado del arte, se llega a la conclusión de que no hay suficiente conocimiento (hasta donde se ha investigado) sobre el fenómeno del backdraft. Por este motivo, a partir de este punto la investigación se centra en el fenómeno del flashover.

Debido a la complejidad de obtener una base de datos de casos reales

relacionados con estos fenómenos, se ha adoptado por utilizar técnicas de modelado y simulación. En esta tesis se proponen dos métodos para crear y validar un conjunto de datos sintéticos. El primer método se basa en la obtención de las imágenes sintéticas a partir de los datos de simulaciones obtenidas con un software de simulación de fluidos computacional (CFD, *Computational Fluid Dynamics*). Para validar el conjunto de datos sintéticos se propone un segundo método que consiste en comparar cuantitativamente los datos obtenidos con dos experimentos reales haciendo uso de la distancia Wasserstein.

Finalmente, para predecir el fenómeno flashover se propone un método de predicción usando el conjunto de datos sintéticos creado. Para probar el modelo de predicción resultante se realizan dos experimentos reales. De los resultados obtenidos se concluye que es posible predecir el fenómeno flashover con el método propuesto.

# Índice de Contenidos

---

<b>Índice de Figuras</b>	XVII
<b>Índice de Tablas</b>	XXVII
<b>1. Introducción</b>	<b>1</b>
1.1. Motivación y contexto	1
1.2. Descripción del problema	5
1.2.1. Flashover	9
1.2.2. Backdraft	11
1.3. Propuesta de solución	14
1.4. Objetivo general y objetivos específicos	15
1.5. Estructura de la tesis	17
1.6. Convenciones de escritura	17
<b>2. Estado del arte</b>	<b>19</b>
2.1. Introducción	19
2.2. Técnicas de modelado	20
2.2.1. Modelado del flashover	20
2.2.2. Modelado del backdraft	23
2.3. Simulación del flashover y backdraft	25
2.3.1. Validación de modelos de campo	27
2.3.2. Simulación del flashover	29
2.3.3. Simulación del backdraft	30
2.4. Sintetizado y comparación de imágenes	33
2.5. Predicción del flashover y backdraft	37

2.6. Conclusiones	43
<b>3. Modelado de la imagen térmica</b>	<b>49</b>
3.1. Introducción	49
3.2. Método para generar conjuntos de datos de imágenes sintéticas	53
3.2.1. Simulaciones numéricas	53
3.2.2. Generación de imágenes sintéticas	60
3.2.3. Generación del conjunto de datos sintéticos	62
3.3. Método de validación y clasificación	62
3.3.1. Distancia Wasserstein	63
3.3.2. Tratamiento de las imágenes sintéticas	65
3.3.3. Convolución WD	65
3.3.4. Validación y clasificación	65
3.4. Método experimental	66
3.4.1. Detalles experimentales	66
3.4.2. Dispositivos de medida	72
3.5. Resultados y discusión	76
3.5.1. Experimento y simulación 1	77
3.5.2. Experimento y simulación 2	83
3.6. Conclusiones	88
<b>4. Método de predicción del flashover</b>	<b>91</b>
4.1. Introducción	91
4.2. HMM para predicción del flashover	96
4.2.1. Vector de características de la imagen	97
4.2.2. Elección del clasificador	99
4.2.3. Entrenamiento y comprobación del modelo	100
4.3. Método experimental	106
4.4. Resultados y discusión	108
4.5. Conclusiones	126
<b>5. Conclusiones</b>	<b>129</b>
5.1. Conclusiones generales	129
5.2. Publicaciones y visibilidad	133
5.3. Líneas futuras	134

<b>Apéndices</b>	<b>137</b>
<b>A. Summary and conclusions</b>	<b>139</b>
A.1. Summary . . . . .	139
A.1.1. Context and motivation . . . . .	139
A.1.2. Solution proposal . . . . .	146
A.1.3. State of art . . . . .	147
A.1.4. Image modelling . . . . .	150
A.1.5. Prediction method . . . . .	160
A.2. Conclusions and future work . . . . .	166
<b>B. Configuración de las simulaciones</b>	<b>171</b>
<b>Bibliografía</b>	<b>177</b>
<b>Lista de Acrónimos</b>	<b>187</b>



Universitat d'Alacant  
Universidad de Alicante



# Índice de Figuras

---

1.1. Distribución de fuegos por tipología. Centro de estadísticas del CTIF 2018 [8] . . . . .	6
1.2. Efectos que se generan en un espacio confinado debido a la transferencia de calor. (a) Vista esquemática: las flechas azules indican la transferencia de calor que no es utilizada por el proceso de combustión. 'rad' se refiere a la transmisión de calor por radiación, 'cond' a la transmisión por conducción y 'conv' a la convección. La flecha en color negro hace referencia al caudal másico de gases combustibles [57]. (b) Imagen térmica de la transferencia de calor en un incendio confinado durante un entrenamiento, en un contenedor de fuego, en el parque de bomberos de San Vicente del Raspeig, Alicante, España. . . . .	8
1.3. Comparación de los fenómenos <i>flashover</i> y <i>backdraft</i> . (a) Curva de desarrollo del incendio en la que se puede ver la etapa de transición conocida como <i>flashover</i> . (b) Curva de desarrollo del fenómeno <i>backdraft</i> sobre la curva de incendio. 13	13
1.4. <i>flashover</i> inducido por ventilación y comparación entre este y el fenómeno <i>backdraft</i> . (a) Curva de desarrollo del <i>flashover</i> inducido por ventilación. (b) Gráfico de comparación del <i>flashover</i> inducido por ventilación y el <i>backdraft</i> sobre la curva de incendio. El área en color gris marca la posibilidad de ocurrencia del <i>flashover</i> inducido por ventilación y el <i>backdraft</i> indistintamente. . . . .	14

1.5. Sketch del método propuesto en esta tesis para la predicción del fenómeno <i>flashover</i> . . . . .	15
2.1. Secuencia de transformación de la imagen . . . . .	34
3.1. Métodos propuestos en este capítulo. Método para generar el conjunto de datos sintéticos (línea discontinua azul). Método para validar y clasificar el conjunto de datos sintéticos (línea discontinua roja) . . . . .	52
3.2. Flujograma del método propuesto para generar el conjunto de datos sintéticos. . . . .	54
3.3. Flir E75, campo de visión (FoV, <i>Field of View</i> ) en la simulación . . . . .	55
3.4. Disposición óptica ideal de la TC según el área de interés elegida . . . . .	56
3.5. Configuración de la simulación para experimento 1. Los límites de las diferentes mallas pueden identificarse en color rosa. (a) Configuración de mallas para el experimento 1. El punto verde simboliza el PTHFM (b) Vista en alzado. (c) Vista frontal. (d) Vista en planta. . . . .	58
3.6. Configuración de la simulación para experimento 2. Los límites de las diferentes mallas pueden identificarse en color rosa. (a) Configuración de mallas para el experimento 2. Puede identificarse el PTHFM en color amarillo encima del hueco de ventilación. (b) Vista en alzado. (c) Vista frontal. (d) Vista en planta. . . . .	59
3.7. Representación térmica del área de interés en la simulación 2	60
3.8. Método propuesto para la generación de imágenes sintéticas para la predicción del <i>flashover</i> . Las líneas de visión atraviesan el humo (área de interés) en dirección a la TC. . . .	61
3.9. Método para validar y clasificar el conjunto de datos sintéticos	63
3.10. Representación de la teoría de OT en dos distribuciones de probabilidad . . . . .	64

3.11. Método experimental propuesto. La imagen superior-izquierda muestra la localización de los experimentos en el interior del contenedor de fuego. Arriba a la derecha se muestra la localización de la cámara en el experimento. Las imágenes en el plano inferior muestran un sketch del recinto confinado y la localización de los dispositivos de medida utilizados. . . .	67
3.12. Sketch del experimento 2. . . . .	68
3.13. Flir E75, campo de visión (FoV, <i>Field of View</i> ) en el experimento . . . . .	70
3.14. Imágenes de la TC. (a) Representa la imagen original, usada en la primera comparación. (b) El cuadrado rojo representa el área de interés (ROI) de la imagen original para hacer la segunda comparación. . . . .	71
3.15. (a) Imagen de la TC incluyendo parte del recinto a una distancia de 94.33 cm. (b) Imagen sintética del área de interés (ROI) correspondiente a una distancia de 71.87 cm. . . . .	72
3.16. Disposición óptica de la TC en el experimento . . . . .	73
3.17. Plate Thermometer Heat Flux Meter <a href="#">[80]</a> . . . . .	74
3.18. Datos de los sensores del experimento 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas rojas. . . . .	78
3.19. Datos de sensores en simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas azules. . . . .	78
3.20. Convolución WD entre las imágenes de la cámara térmica (ROI) en el experimento 1 y las imágenes de la simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas. . . . .	79
3.21. Convolución WD entre las imágenes de la cámara térmica (IMAGE) en el experimento 1 y las imágenes de la simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas. . . . .	79

3.22. Datos de los sensores del experimento 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas de trazos rojos. . . . .	85
3.23. Datos de los sensores en la simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas azules. . . . .	85
3.24. Convolución WD entre las imágenes de la cámara térmica (ROI) en el experimento 2 y las imágenes de la simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas. . . . .	86
3.25. Convolución WD entre las imágenes de la cámara térmica (IMAGE) en el experimento 2 y las imágenes de simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas. . . . .	86
4.1. Arquitectura HMM . . . . .	94
4.2. La imagen muestra un modelo para el caso propuesto de predicción del <i>flashover</i> con dos estados ocultos y diferentes estados observables. . . . .	96
4.3. Representación de la obtención del vector de características a partir de la imagen observada sumando las intensidades de cada columna de la imagen obtenida con la cámara térmica. . . . .	98
4.4. Representación de la obtención del vector de características a partir de la imagen observada obteniendo la desviación típica de la imagen. . . . .	99
4.5. Evolución del incendio en la simulación AI-1. . . . .	102
4.6. Evolución del incendio en la simulación AI-24. La línea discontinua de color rojo muestra el momento en el que el <i>flashover</i> se produce. . . . .	102
4.7. Evolución del incendio en la simulación AI-25. La línea discontinua de color rojo muestra el momento en el que el <i>flashover</i> se produce. . . . .	103

4.8. Evolución del incendio en la simulación AI-41. La línea discontinua de color rojo muestra el momento en el que el <i>flashover</i> .	103
4.9. Curva ROC	105
4.10. Datos de los sensores en la simulación 3. Los números 1,2,3 y 4 representan los diferentes estados, limitados por líneas discontinuas rojas, en los que se ha dividido la curva de fuego.	107
4.11. Datos de los sensores en la simulación 4. Los números 1,2,3 y 4 representan los diferentes estados delimitados por líneas discontinuas rojas. La línea de puntos en la etapa 4 representa el momento en el que la radiación a nivel de suelo alcanza $20 \text{ kW/m}^2$ .	107
4.12. HMM para 2 estados en la simulación AI-24. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.	116
4.13. HMM para 3 estados en la simulación AI-24. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto.	116
4.14. HMM para 2 estados en la simulación AI-25. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.	117
4.15. HMM para 3 estados en la simulación AI-25. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto.	117
4.16. HMM para 2 estados en la simulación AI-41. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.	118

4.17. HMM para 3 estados en la simulación AI-41. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto. . . . .	118
4.18. HMM para 2 estados ocultos en la simulación AI-6. La línea vertical azul divide la curva de fuego en los estados ocultos.	120
4.19. HMM para 3 estados ocultos en la simulación AI-6. Las líneas verticales verde y azul dividen la curva de fuego en los estados ocultos. . . . .	121
4.20. HMM para 2 estados ocultos en la simulación del experimento 2 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo. . . . .	122
4.21. HMM para 3 estados ocultos en la simulación del experimento 2 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo. . . . .	123
4.22. HMM para 2 estados ocultos en el experimento 4 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo. . . . .	124
4.23. HMM para 3 estados ocultos en el experimento 4 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y la verde y azul en los estados ocultos según el modelo. . . . .	125
A.1. Distribution of fires by types. International Association of Fire and Rescue Services by Center of Fire Statistics of CTIF 2018 [8]. . . . .	140
A.2. <i>Flashover</i> and ventilation induced <i>flashover</i> . (a) <i>Flashover</i> representation as a transition phase in the fire standard curve before the fully developed fire stage in an enclosure. (b) VIF as a consequence of an infraventilated fire. . . . .	144

A.3. Ventilation induced <i>flashover</i> (VIF) and comparison between VIF and <i>backdraft</i> . (a) <i>backdraft</i> representation. (b) Comparison between <i>backdraft</i> and VIF. . . . .	145
A.4. Enclosure effects on heat transfer in a fire container. (a) Schematic overview: Blue arrows indicate heat transfer, which is not used in the fire process; “rad” refers to radiation, “cond” refers to conduction and “conv” refers to convection. The curved arrow refers to the mass flow rate of combustible gases [57]. (b) Thermal image of enclosure effects in a fire container during a firefighting training at San Vicente Fire Station, Alicante, Spain. . . . .	148
A.5. Method to generate the synthetic data-set (blue dashed line) and method to validate and classify the synthetic data-set (red dashed line) . . . . .	151
A.6. Proposed method for generating synthetic images for <i>flashover</i> prediction. The lines of sight pass through the smoke (area of interest) towards the thermal camera. . . . .	152
A.7. Images from TC. (a) IMAGE (b) ROI. . . . .	153
A.8. Area of interest in a simulation . . . . .	154
A.9. Data from sensors in experiment 1. Numbers 1, 2, 3 and 4 represents different stages in the experiment surrounded by red dash lines. . . . .	156
A.10. Data from sensors in simulation1. Numbers 1, 2, 3 and 4 represents different stages in the simulation surrounded by blue dash lines. . . . .	157
A.11. WD convolution between thermal camera and simulation ROI images in experiment 1. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines. . . . .	157
A.12. WD convolution between thermal camera and simulation IMAGE images in experiment 1. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines. . . . .	158
A.13. Data from sensors in experiment 2. Numbers 1, 2, 3 and 4 represents different stages in the experiment surrounded by red dash lines. . . . .	158

A.14.Data from sensors in simulation 2. Numbers 1, 2, 3 and 4 represents different stages in the simulation surrounded by blue dash lines	159
A.15.WD convolution between thermal camera and simulation ROI images in experiment 2. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines	159
A.16.WD convolution between thermal camera and simulation IMAGE images in experiment 2. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines.	160
A.17.Model for the proposed case of <i>flashover</i> prediction with two hidden states (No <i>flashover</i> and <i>flashover</i> ) and different observable states (frames).	162
A.18.HMM for 2 states in AI-24 simulation. The red vertical line corresponds to the prediction based on the observed data. The blue vertical line divides the fire curve in the 2 states according to the proposed model.	163
A.19.HMM for 3 states in AI-24 simulation. Red vertical line corresponds to prediction based on observed data. The vertical green and blue lines divide the fire curve into 3 states according to the proposed model.	164
A.20.HMM with 3 hidden states in experiment in simulation AI-6. The red vertical lines divide the fire curve in the observed states and the blue lines in the hidden states according to the model.	166
A.21.HMM with 2 hidden states in the simulation of experiment 2. The red vertical lines divide the fire curve in the observed states and the blue lines in the hidden states according to the model.	167
A.22.HMM with 3 hidden states in the simulation of experiment 2. The red vertical lines divide the fire curve in the observed states and the blue and green lines in the hidden states according to the model.	167

A.23.HMM with 2 hidden states in experiment 4. The red vertical	
lines divide the fire curve in the observed states and the blue	
lines in the hidden states according to the model. . . . .	168
A.24.HMM with 3 hidden states in experiment 4. The red vertical	
lines divide the fire curve in the observed states and the blue	
and green lines in the hidden states according to the model.	168



Universitat d'Alacant  
Universidad de Alicante



# Índice de Tablas

---

1.1. Población, muertes per cápita por año (por 100 000 habitantes) y porcentaje de fuegos catastróficos en los países europeos seleccionados [58]. . . . .	6
1.2. Datos de incendios confinados en viviendas según su uso (NFPA [4]). Los datos mostrados se corresponden con la media anual en el período que va desde 2010 a 2014. . . . .	7
1.3. Flujo de calor radiante aproximado [60]. . . . .	10
2.1. Trabajos relevantes sobre dinámica del fuego en recintos confinados. . . . .	21
2.2. Referencias sobre el modelado de los fenómenos <i>flashover</i> y <i>backdraft</i> . . . . .	25
2.3. Referencias sobre la simulación de los fenómenos <i>flashover</i> y <i>backdraft</i> . . . . .	33
2.4. Referencias sobre la predicción de los fenómenos <i>flashover</i> y <i>backdraft</i> . . . . .	43
3.1. Consumo de combustible en el experimento 1 . . . . .	57
3.2. Evolución de la combustión del tablero de madera MDF usada en ambos experimentos. . . . .	57
3.3. Consumo de combustible en el experimento 2 . . . . .	59
3.4. PTHFM, especificaciones técnicas . . . . .	75
3.5. FlirE75, especificaciones técnicas . . . . .	75

3.6. Matriz de confusión para el experimento 1 (ROI) y la simulación 1. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.	82
3.7. Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 1 (ROI) y simulación 1.	82
3.8. Matriz de confusión para el experimento 1 (IMAGE) y la simulación 1. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.	82
3.9. Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 1 (IMAGE) y simulación 1.	83
3.10. Matriz de confusión para el experimento 2 (ROI) y la simulación 2. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.	87
3.11. Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 2 (ROI) y simulación 2.	88
3.12. Matriz de confusión para el experimento 2 (IMAGE) y la simulación 2. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.	88
3.13. Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 2 (IMAGE) y simulación 2.	88
4.1. Parámetros de una cadena de Markov	93
4.2. Parámetros de un modelo oculto de Markov	95
4.3. Configuración de la Matriz de confusión	105
4.4. Resultados de las pruebas realizadas con los clasificadores continuos de la herramienta hmmlearn de Scikit Learn	109

4.5. Resultados de las pruebas realizadas para determinar el vector de características sin tratamiento de la imagen térmica.	111
4.6. Resultados de las pruebas realizadas para determinar el vector de características con tratamiento de la imagen térmica.	112
4.7. Resultados de las pruebas realizadas para determinar el vector de características aplicando WD con tratamiento de la imagen térmica.	114
4.8. Matriz de confusión para el modelo de 2 estados ocultos obtenida a partir de aplicar el modelo sobre las 64 simulaciones restantes.	119
4.9. Matriz de confusión para el modelo de 3 estados obtenida a partir de aplicar el modelo sobre las 64 simulaciones restantes.	119
4.10. Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para los modelos estudiados de 2 y 3 estados a partir de la simulación AI-24.	119
5.1. Valores de precisión para método propuesto con HMM y tres estados	130
A.1. Population, fatalities per capita per year and percentage of fatal fires in selected European countries [58].	140
A.2. Reported home structure fires by property use (NFPA [4]), 2010–2014 annual averages.	141
A.3. Approximate radiant heat flux [60].	143
A.4. Confusion matrix for experiment and simulation 1 ROI images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.	154
A.5. Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 1 ROI images.	154
A.6. Confusion matrix for experiment and simulation 1 IMAGE images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.	155

A.7. Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 1 IMAGE images	155
A.8. Confusion matrix for experiment and simulation 2 ROI images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.	155
A.9. Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 2 ROI images	155
A.10. Confusion matrix for experiment and simulation 2 IMAGE images. R1, R2, R3 and R4 represent the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.	156
A.11. Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 2 ROI images	156
A.12. Hidden Markov Model Parameters	161
A.13. Results of the tests carried out to determine the vector of characteristics with thermal imaging treatment using simulations AI-24, AI-25 and AI-41.	163
A.14. Confusion matrix for the 2 hidden state model (AI-24) obtained from applying the model to the 64 remaining simulations.	164
A.15. Confusion matrix for the 3 hidden state model (AI-24) obtained from applying the model to the 64 remaining simulations.	164
A.16. Sensitivity, specificity, precision, negative predictive values and accuracy for the 2 and 3-state models studied from the AI-24 simulation.	165
B.1. Configuración de las simulaciones	172

# Introducción

---

Este primer capítulo presenta el tema principal de esta tesis y está organizado en los siguientes apartados: en la sección [1.1](#) se presenta la motivación que llevó a la realización de este trabajo y se expone el contexto; el apartado [1.2](#) muestra una descripción del problema que se plantea en esta investigación; la sección [1.3](#) describe la propuesta de solución; el apartado [1.4](#) resume los principales objetivos de este estudio; en el apartado [1.5](#) se describe la estructura de este documento; y finalmente, en la sección [1.6](#) se exponen las convenciones de escritura utilizadas en el documento.

## 1.1. Motivación y contexto

Durante las últimas décadas, se ha producido un aumento considerable de la población. Según datos de la Organización de Naciones Unidas (ONU), actualmente más de la mitad de la población (el 54.5%) vive hoy en ciudades y se prevé que esta cifra aumente un 13% de cara a 2050. La principal causa de este aumento de población en las ciudades reside en el cambio de residencia de parte de la población, que cambiará las zonas rurales por las urbanas. A todo lo anterior hay que añadir los datos de crecimiento demográfico, según los que cerca de 2 500 millones de personas adicionales vivirán en las ciudades para esa fecha (información aportada por el departamento de asuntos económicos y sociales de la ONU). Este aumento de población en las urbes está directamente relacionado con la cantidad de situaciones de emergencias de diferente índole que atienden

los servicios de bomberos. En esta línea hay que prestar especial atención a los incendios que se producen en viviendas, sobre todo a los que están localizados en ciudades. Los edificios que se construyen cada vez albergan mayor número de personas en su interior, lo que conlleva una cantidad mayor de suministros (como pueden ser electricidad, gas, etc.) aumentando la peligrosidad en este tipo de intervenciones. A esto hay que añadir el peligro potencial que suponen los materiales que algunos propietarios almacenan en sus domicilios. Los incendios en viviendas o también llamados incendios confinados (el incendio transcurre en el interior de un recinto con o sin ventilación) suponen un riesgo para los equipos de intervención que actúan en este tipo de emergencias. En este tipo de fuegos se pueden dar situaciones muy peligrosas como las que ocurren cuando aparecen los fenómenos del *flashover* o *backdraft*, a los que hay que prestar mucha atención, ya que pueden suponer un riesgo mortal para los intervinientes.

En los últimos 20 años, como personal operativo del Consorcio de Bomberos de Alicante, he tenido la oportunidad de intervenir en multitud de incendios confinados de diferente magnitud. Esto me ha permitido conocer de primera mano la complejidad de este tipo de fenómenos, así como su peligrosidad tanto para los actuantes como para las personas que se ven involucradas en ellos. La seguridad del personal que participa en estas intervenciones es de vital importancia para que la emergencia se resuelva de una manera eficaz. Por este motivo, la pregunta que motiva este trabajo de investigación es: ¿sería posible desarrollar un método para ayudar a predecir este tipo de situaciones utilizando cámaras de imagen térmica?

Con la incorporación de las cámaras de imagen térmica (TC, *Thermal Camera*) en los servicios de bomberos, es posible identificar determinadas situaciones potencialmente peligrosas para los equipos de intervención que participan en tareas de extinción y rescate. Este tipo de cámaras, facilitan al usuario una importante información en tiempo real que, en manos de profesionales experimentados, puede ser de vital importancia para su seguridad [75] y la de todos los participantes en este tipo de emergencias. Sin embargo, se debe prestar especial atención a aquellas situaciones en

las que los fenómenos *flashover* o *backdraft* [60] tienen una probabilidad alta de que ocurran. En este tipo de situaciones es importante que los equipos de emergencia tengan un alto grado de conocimiento sobre la dinámica que se da en los incendios confinados (ver figuras 1.2a y 1.2b), para poder anticiparse a las posibles consecuencias. En ocasiones, esto no es posible debido a la cantidad de tareas que el equipo de intervención tiene que atender simultáneamente, además del estrés añadido que este tipo de situaciones supone para los bomberos. El uso de TC permite identificar ciertos parámetros del escenario que no podrían ser evaluados de otra manera, minimizando la carga de trabajo y el estrés al poder ser valorada la situación a través de la imagen térmica que obtenemos con este tipo de tecnología. Actualmente, los modelos de cámaras usadas por los servicios de bomberos disponen de varias funciones como la detección de personas o localización de puntos calientes entre otras. Además, esta tecnología ofrece dos modos de sensibilidad (alta y baja) y la escala de temperaturas se muestra automáticamente en función del modo seleccionado. Incluso es posible conocer la temperatura aproximada de un punto en concreto del escenario haciéndolo coincidir con el centro de la imagen en la pantalla de la cámara térmica (ver figura 1.2b). No obstante, esto no es del todo correcto cuando lo que se pretende es averiguar la temperatura de la capa de gases, ya que la temperatura mostrada por la cámara es la temperatura reflejada por el techo del recinto y no la temperatura interior de la capa de gases. Debido al espectro de la luz visible, pequeñas partículas en el aire, como partículas de carbono en la capa de humo o el vapor de agua, pueden interferir con la luz visible reflejada. Por el contrario, la luz infrarroja tiene una longitud de onda mayor que la luz visible, por lo que las partículas de la capa de humo no la reflejan fácilmente. Este hecho debe tenerse en cuenta para la medición de la temperatura de capa de humo con una cámara de imagen térmica.

Para intentar prevenir el fenómeno de *flashover* descrito en este documento, el bombero que sujeta la cámara de imagen térmica debe monitorear la capa de gases, desde el interior del recinto, para detectar cambios de temperatura en esta. Si bien, esta técnica no es muy precisa, ya que ade-

más de lo comentado en el párrafo anterior depende en exceso del factor humano. A esto último hay que añadir que, la cámara de imagen térmica no es utilizada únicamente para este propósito, ya que también se utiliza para orientar al equipo en el interior del recinto y para la búsqueda de posibles víctimas. Esto último provoca que el bombero no pueda centrarse exclusivamente en la evaluación de la temperatura de la capa de gases.

En el caso de una situación potencial de *backdraft*, los bomberos tienen que evaluar otros factores que determinan su posible aparición, como un color entre amarillento y marrón de los humos, ausencia de llamas, cristales ennegrecidos por el humo, sobrepresión en el interior, calor elevado o corrientes de aire pulsante. Por otra parte, hay que tener en cuenta que, en este tipo de situaciones el humo inunda por completo el recinto confinado lo que dificulta el uso de las TC si la temperatura de los gases es elevada. Hay que añadir que, actualmente no hay una relación estrecha entre la temperatura de la capa de gases y la aparición de este fenómeno. Por esta razón, las TC no son usadas por los servicios de bomberos para determinar la posibilidad de ocurrencia del fenómeno *backdraft*.

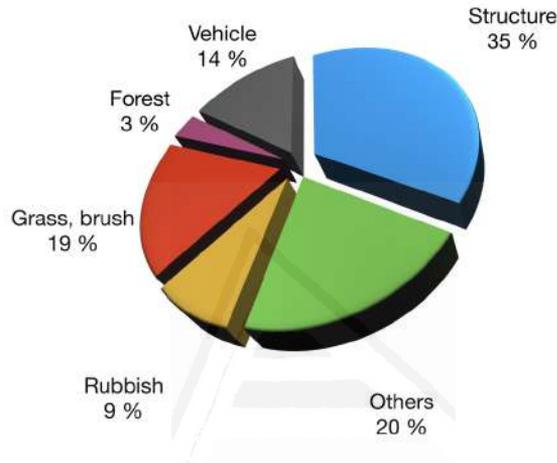
Por otro lado, tenemos que ser capaces de facilitar al equipo de intervención, información en tiempo real de la evolución del incendio liberando de esta tarea al personal que está en primera línea. La aplicación de técnicas de inteligencia y visión artificial en varias áreas de la ciencia del fuego, ha supuesto que se puedan identificar y predecir ciertos fenómenos lo que abre la puerta a la resolución de problemas que previamente no han podido ser tratados. Por este motivo, la principal motivación de este trabajo es contribuir al aumento de seguridad de los equipos de intervención en este tipo de emergencias, desarrollando un método para predecir este tipo de situaciones.

## 1.2. Descripción del problema

Los incendios confinados son situaciones con las que los bomberos tienen que lidiar constantemente y las terribles consecuencias de este tipo de emergencia pueden afectar tanto a personas, como a las estructuras que se ven envueltas en este tipo de siniestros. Esto se debe a que la evolución del incendio de interior puede desembocar en situaciones que dan lugar a fenómenos extremadamente peligrosos, como pueden ser el *flashover* y el *backdraft*.

Un incendio confinado es aquel que tiene lugar en el interior de una estructura cerrada como pueden ser: casas unifamiliares, garajes, pisos, establecimientos comerciales, etc. El último estudio [8] de la asociación internacional de servicios contra incendios y rescate (CTIF, *International Association of Fire and Rescue Services*) revela que el 35% de los fuegos que se producen en multitud de ciudades en todo el mundo son incendios confinados (ver figura 1.1). Esta clase de emergencias causan anualmente, la muerte y heridas de diversa consideración a personas no relacionadas con las tareas de extinción, además de importantes daños estructurales. Actualmente, los datos sobre este tipo de emergencias son muy escasos en Europa. Esto es debido, principalmente, a que no hay una base de datos común que involucre a todos los países miembros, además de que muchos de los servicios de bomberos no documentan adecuadamente este tipo de intervenciones. Un ejemplo de esto es el estudio llevado a cabo por la Alianza Europea de Seguridad Contra Incendios (EFSA, *European Fire Safety Alliance*), el cual únicamente incluye diez países. Para comparar estos resultados con datos de otro continente, es posible consultar las estadísticas elaboradas por la Asociación Nacional de Protección Contra Incendios (NFPA, *National Fire Protection Association* [4]) de Estados Unidos de América (USA, *United States of America*). Según los datos facilitados por la NFPA, durante el período comprendido entre 2010 y 2014, los servicios de bomberos estadounidenses intervinieron en una media anual de 358 300 fuegos confinados o estructurales. Este tipo de emergencias causaron 2 520 muertes de media al año, 12 720 daños a personas (excluyendo personal

del servicio de bomberos) y 6.7 billones de dólares en daños directos a la propiedad. Siete personas murieron en USA cada día de media en incendios confinados en viviendas durante este período. En la tabla 1.1 se muestran los resultados del análisis llevado a cabo por EFSA [58] sobre los fuegos residenciales o fuego en domicilios particulares.



**Figura 1.1:** Distribución de fuegos por tipología. Centro de estadísticas del CTIF 2018 [8]

**Tabla 1.1:** Población, muertes per cápita por año (por 100 000 habitantes) y porcentaje de fuegos catastróficos en los países europeos seleccionados [58].

País	Población (Millones)	Muertes per capita por año (Aprox.)	% Fuegos catastróficos (Relacionados con fuegos residenciales)
Bélgica (2014–2015)	11.4	0.6	0.5
Dinamarca (2011–2012)	5.8	1.1	1.2
Estonia (2013–2017)	1.3	3.7	4.6
Finlandia (2011–2012)	5.53	1.4	
Holanda (2011–2014)	17	0.2	0.6 %
Noruega (2016–2017)	5.3	0.5	1.3 %
Polonia (2011–2012)	38	1.3	
Suecia (2011–2013)	10	1.1	1.2 %
Reino Unido (2014)	66	0.6	
<b>Total</b>	<b>160.3</b>		
<b>Total Europa</b>	<b>742.9</b>		

Para hacernos una idea de los riesgos a los que se ven expuestos las personas que se encuentran en este tipo de situaciones, en la tabla 1.2 se muestra las pérdidas por ocupación en dos tipos de viviendas, viviendas unifamiliares y pisos. El 70 % de los incendios y el 84 % de los incendios más graves en viviendas tuvieron lugar en domicilios de una o dos habitaciones en casas unifamiliares, incluidas las viviendas prefabricadas.

**Tabla 1.2:** Datos de incendios confinados en viviendas según su uso (NFPA [4]). Los datos mostrados se corresponden con la media anual en el período que va desde 2010 a 2014.

Uso de la propiedad	Fuegos	Muertes	Daños personales	Daños directos a estructuras (en millones)
Casas unifamiliares, incluyendo prefabricadas <sup>1</sup>	250 500 (70 %)	2 100 (84 %)	8 440 (66 %)	\$5 438 (81 %)
Otro tipo de viviendas <sup>2</sup>	107 800 (30 %)	410 (16 %)	4 280 (34 %)	\$1 271 (19 %)
Total	358 300 (100 %)	2 520 (100 %)	12 720 (100 %)	\$6 710 (100 %)

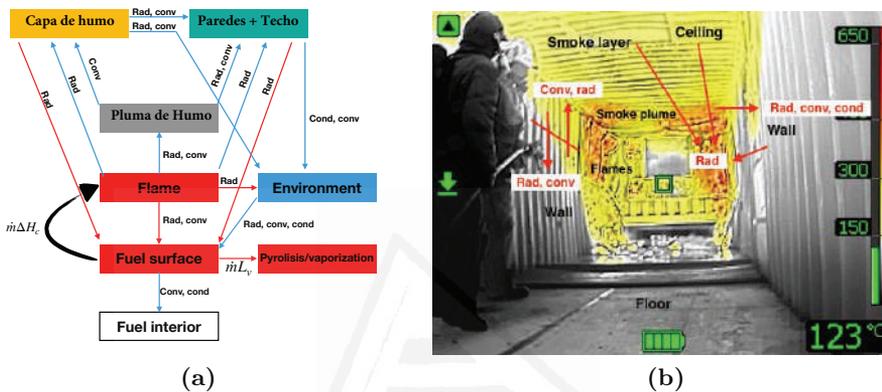
<sup>1</sup> Una o más habitaciones han sido consideradas para la realización del estudio; <sup>2</sup> Viviendas unifamiliares, dúplex, casas prefabricadas, apartamentos, pareados y casas adosadas. Otro tipo de propiedades residenciales como hoteles y moteles, dormitorios, cuarteles, pensiones y similares, no están incluidas. Para el estudio se han considerado una o más habitaciones.

Teniendo en cuenta que este tipo de emergencias se desarrollan en recintos confinados, se pueden dar las siguientes circunstancias dependiendo de la ventilación existente:

- **El recinto está ventilado:** el consumo de oxígeno como consecuencia del proceso de combustión es menor que el oxígeno disponible.
- **El recinto está poco ventilado:** falta de entrada de aire o falta de salida para el humo. Durante el proceso de combustión, los niveles de oxígeno en el recinto disminuyen. La inexistencia de huecos de ventilación o el desplazamiento de oxígeno por los gases de combustión pueden ser las causas de la falta de ventilación.

Para entender el proceso de combustión que tiene lugar en un recinto

confinado es necesario introducir los conceptos de fuego controlado por el combustible (FC, *Fuel Controlled*) y controlado por ventilación (VC, *Ventilation Controlled*). Si en el recinto hay suficiente cantidad de oxígeno como para consumir los gases generados como consecuencia del proceso de pirólisis que tiene lugar, decimos que estamos ante un escenario controlado por el combustible.



**Figura 1.2:** Efectos que se generan en un espacio confinado debido a la transferencia de calor. (a) Vista esquemática: las flechas azules indican la transferencia de calor que no es utilizada por el proceso de combustión. 'rad' se refiere a la transmisión de calor por radiación, 'cond' a la transmisión por conducción y 'conv' a la convección. La flecha en color negro hace referencia al caudal másico de gases combustibles [57]. (b) Imagen térmica de la transferencia de calor en un incendio confinado durante un entrenamiento, en un contenedor de fuego, en el parque de bomberos de San Vicente del Raspeig, Alicante, España.

Por el contrario, si la cantidad de oxígeno en el ambiente no es suficiente para que la reacción de combustión pueda continuar, el escenario está controlado por la ventilación (VC). Teniendo en cuenta estos dos tipos de situaciones (ventilada e infra-ventilada), una vez que tiene lugar la ignición en un material la situación puede desarrollarse de diferentes maneras. En un recinto ventilado si el proceso de combustión termina momentos después de la ignición, la energía liberada por el mismo no es suficiente para generar nuevos gases, procedentes del proceso de pirólisis, en el material o en materiales próximos. Esta causa hace que el fuego no pueda propagarse (FC). Por otro lado, si el recinto está infra-ventilado, la falta de oxígeno

puede originar que la mezcla combustible comburente no sea la adecuada impidiendo el proceso de combustión (VC). Otra posibilidad es cuando la tasa de calor liberado, procedente del proceso de combustión, es suficiente para generar nuevos gases de pirólisis a partir de material que todavía no ha sido quemado, y el oxígeno en el ambiente es suficiente para mantener el proceso de combustión. Si esto sucede, el fuego puede alcanzar la fase de crecimiento (growing stage), donde el fuego puede propagarse a través de la superficie del material o alcanzar otras superficies por medio de la transferencia de calor por radiación. En un recinto ventilado, en el que todo el combustible disponible puede arder, el fuego puede entrar en la fase de decaimiento después de que esto ocurra o se puede dar una transición de FC a VC apagando el incendio debido a la falta de oxígeno. En algunos casos, el incendio puede crecer hasta alcanzar la fase de completamente desarrollado después de pasar por una etapa de transición conocida como *flashover*.

### 1.2.1. Flashover

El fenómeno *flashover*, o también conocido como combustión súbita generalizada, se define como una etapa de transición rápida hacia un incendio totalmente desarrollado (ver figura [1.3a](#)) que ocurre en un recinto confinado en el que de repente, todas las superficies de los combustibles (que hasta el momento no estaban involucradas en el incendio) empiezan a arder debido a la radiación recibida desde la capa de gases que se acumula bajo el techo. A causa de esto, todo el recinto se ve envuelto en llamas, un hecho que marca el máximo desarrollo del incendio. En esta situación, pueden ser alcanzados valores de radiación por encima de  $170 \text{ kW/m}^2$  (ver tabla [1.3](#)), superiores a los que se utilizan para certificar la ropa que usan los bomberos en este tipo de intervenciones ( $80 \text{ kW/m}^2$  según NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting). Este último valor ( $80 \text{ kW/m}^2$ ) es aplicado sobre la superficie de cada prenda durante 12 segundos después de 5 ciclos de lavado. En la tabla [1.3](#) se muestran diferentes valores de radiación que pueden ser comparados con los valores que se alcanzan una vez que el incendio se encuentra completamente desa-

rrollado (*post-flashover*).

**Tabla 1.3:** Flujo de calor radiante aproximado [60].

Flujo de Calor Radiante Aproximado (kW/m <sup>2</sup> )	Comentario o Efecto Observado
170	Flujo de calor máximo medido en un compartimento de incendio en la fase <i>post-flashover</i>
80	Flujo de calor para ropa protectora. Prueba de rendimiento de protección térmica (TPP).
52	El tablero de fibra de madera se inflama espontáneamente después de 5 s
29	La madera se inflama espontáneamente después de una exposición prolongada.
20	Flujo de calor en el suelo de una habitación al comienzo del <i>flashover</i> .
16	La piel humana experimenta dolor repentino y ampollas después de 5 segundos de exposición con quemaduras de segundo grado.
12.5	Los productos volátiles de la madera se encienden con la exposición prevista y una fuente de ignición.
10.4	La piel humana experimenta dolor con una exposición de 3 segundos y ampollas en 9 s con quemaduras de segundo grado.
6.4	La piel humana experimenta dolor con una segunda exposición y ampollas en 18 s con quemaduras de segundo grado.
4.5	Aparecen ampollas en la piel humana con una exposición de 30 segundos, causando quemaduras de segundo grado.
2.5	Exposición común a la radiación térmica durante la lucha contra incendios. Este nivel de energía puede provocar quemaduras con exposición prolongada.
1.4	Radiación térmica del sol. Posibles quemaduras solares en 30 minutos o menos.

La NFPA [60] también define el fenómeno del *flashover* como la fase de transición, en el desarrollo de un fuego de interior, en la que las superficies expuestas a la radiación térmica alcanzan la temperatura de ignición simultáneamente y el fuego se propaga rápidamente a las superficies de los materiales disponibles en el recinto.

Como se ha comentado anteriormente, el fenómeno del *flashover* puede darse en espacios confinados con suministro constante de aire (no hay deficiencias de oxígeno) o en recintos infra-ventilados en los que tiene lugar un cambio en la dinámica en la ventilación del incendio (se inicia una ventilación forzada con ventiladores o se abre un nuevo hueco de ventilación accidental o intencionadamente). En las ocasiones en las que ocurre un cambio de ventilación, la situación cambia de VC a FC, decimos que

se ha producido un *flashover* inducido por ventilación (ver figura 1.4a). Teniendo en cuenta todo lo expuesto anteriormente, es necesaria una mínima cantidad de combustible para generar la cantidad adecuada de gases combustibles y radiación para que se pueda dar este tipo de fenómeno. Una vez que se alcanza la etapa de *flashover*, esta puede dar paso a un incendio totalmente desarrollado, pero su potencia y ocurrencia están determinadas por la localización y el tamaño de la abertura de ventilación hacia el exterior.

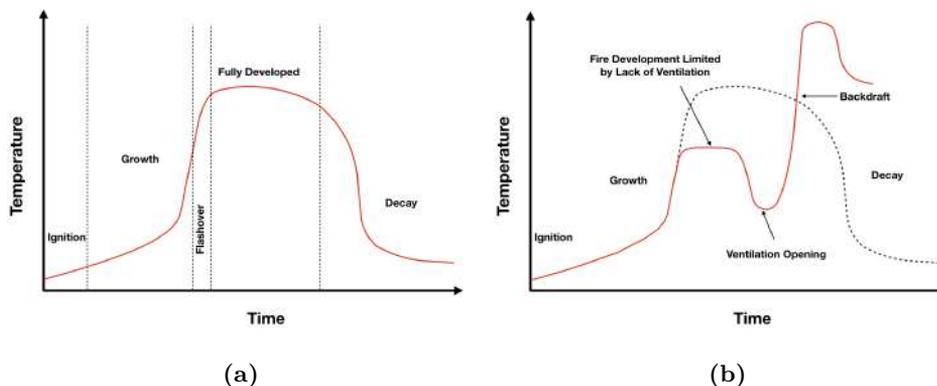
La curva de desarrollo del incendio (ver figura 1.3a) muestra la evolución temporal de un incendio limitado por la cantidad de combustible. La cantidad de oxígeno disponible en la fase que precede al *flashover* (*pre-flashover*) es suficiente para mantener el proceso de combustión y consumir todo el combustible disponible. Cuanto más combustible se ve envuelto en el incendio, los niveles de energía continúan aumentando hasta que todo el combustible disponible en el recinto arde (incendio totalmente desarrollado). A partir de este momento, a medida que el combustible va siendo consumido, los niveles de energía comienzan a caer. En todo momento, hay disponible la suficiente cantidad de oxígeno en la mezcla comburente-combustible para que, en el proceso de combustión, continúe produciéndose la energía necesaria. En algunos casos, cuando la fase de incendio totalmente desarrollado es alcanzada, la tasa de liberación de masa de combustible es demasiado alta y el oxígeno disponible en el recinto no es suficiente para consumir todos los gases procedentes del proceso de pirólisis (cambio de incendio controlado por combustible a incendio controlado por ventilación).

### 1.2.2. Backdraft

El fenómeno conocido como *backdraft* ocurre en espacios confinados con ventilación limitada (ver figura 1.3b), por lo que el crecimiento y la potencia del incendio están limitados por la disponibilidad de oxígeno en el recinto. Este tipo de fenómeno [60] es una deflagración como consecuencia de un aporte repentino de aire a un incendio en un espacio confinado, en el que existen productos (no quemados) procedentes del proceso de una

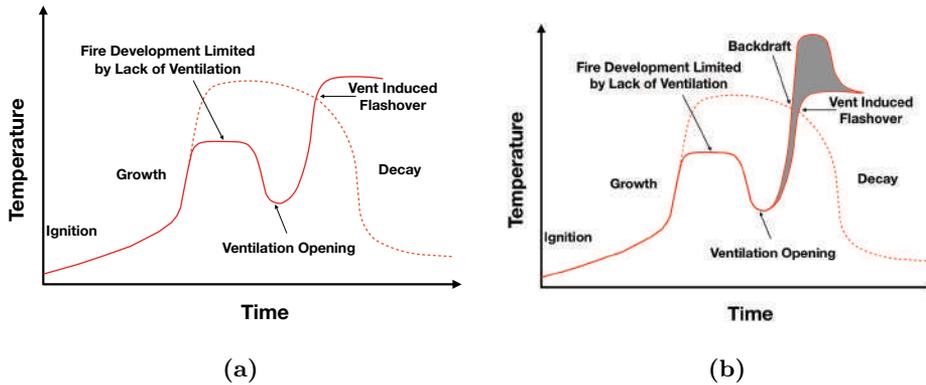
combustión incompleta por falta de oxígeno. En este tipo de escenarios en espacios confinados, el oxígeno presente en el recinto puede alcanzar valores muy bajos debido a que no existe ninguna abertura de ventilación, colocando la mezcla combustible-comburente por encima del rango de inflamabilidad, por lo que el fuego cae en un estado latente. Como consecuencia, la combustión incompleta que se produce por la disminución del oxígeno debido a un consumo creciente en el proceso de combustión provoca la introducción de productos de pirólisis sin quemar en la capa de humo. En este punto, una abertura de ventilación podría hacer que la mezcla combustible-comburente entre dentro del rango de inflamabilidad. Si se da el caso de que la mezcla inflamable se encuentra con una fuente de ignición, la mezcla se enciende y la llama se propaga hacia el hueco de ventilación abierto creando una sobrepresión. Los efectos de turbulencia que se originan como consecuencia de esto último favorecen la mezcla entre combustible y comburente aumentando su inflamabilidad. Una vez los gases del recinto entran en ignición son expulsados al exterior pudiendo adoptar forma de bola de fuego, típicamente asociada con el fenómeno *backdraft* [27, 46]. Aunque tanto el fenómeno *backdraft* como el *flashover* inducido por ventilación (VIF, *Ventilation Induced Flashover*) se originan en recintos con ventilación limitada no pueden ser confundidos, ya que existen notables diferencias entre ambos (ver Figura 1.4b). Hay que tener en cuenta que el VIF puede ser definido como una continuación del desarrollo del incendio una vez que se abre una abertura de ventilación. Grimwood et al [28] define la diferencia entre ambos como un evento de transición (*flashover*) y un evento de paso (*backdraft*).

En vista de la discusión anterior, es interesante mencionar el potencial de la inteligencia artificial (AI, *Artificial Intelligence*) para predecir estos fenómenos. Por esta razón, en el capítulo 2 se hace también una revisión de los trabajos que han aplicado AI en situaciones similares. A través de técnicas de AI, que se centran en el estudio de agentes inteligentes, un dispositivo puede realizar acciones que maximicen las posibilidades de completar con éxito una tarea basada en la percepción del entorno. Algunas técnicas, como la detección de llama, propagación del fuego, clasificación



**Figura 1.3:** Comparación de los fenómenos *flashover* y *backdraft*. (a) Curva de desarrollo del incendio en la que se puede ver la etapa de transición conocida como *flashover*. (b) Curva de desarrollo del fenómeno *backdraft* sobre la curva de incendio.

del fuego y del humo, ocurrencia del fenómeno *flashover*, localización de la interfaz térmica en un recinto confinado de una estancia o técnicas para detectar perfiles de temperatura o velocidad entre otros, han probado que es posible predecir con éxito ciertas situaciones relacionadas con el fuego. Se han utilizado diferentes enfoques para investigar la predicción de incendios, siendo el enfoque más comúnmente adoptado las redes neuronales artificiales (ANN, *Artificial Neural Network*). Las ANN son modelos computacionales que se utilizan ampliamente para encontrar relaciones complejas entre una fuente (entrada) y un objetivo (salida). El uso de esta metodología orientada a la ciencia del fuego parece estar aumentando, así lo demuestra el creciente número de publicaciones en esta área de conocimiento. Por ejemplo, en el reconocimiento de imágenes, el uso de ANN ha demostrado ser capaz de aprender a identificar imágenes que contienen fuego analizando imágenes de entrenamiento y usando los resultados para detectar fuego en otras imágenes. En relación con el conjunto de datos de imágenes, las redes neuronales convolucionales (CNN, *Convolutional Neural Networks*) parecen ser más efectivas para encontrar patrones de alta precisión. Teniendo en cuenta todo lo anterior, vale la pena mencionar que es muy difícil encontrar un conjunto de datos útiles de emergencias reales de *flashover* y *backdraft*. Para abordar este interesante punto, en

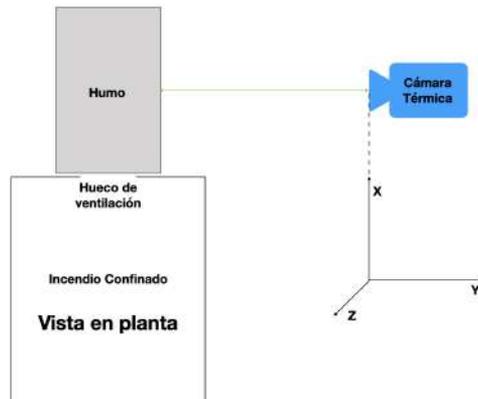


**Figura 1.4:** *flashover* inducido por ventilación y comparación entre este y el fenómeno *backdraft*. (a) Curva de desarrollo del *flashover* inducido por ventilación. (b) Gráfico de comparación del *flashover* inducido por ventilación y el *backdraft* sobre la curva de incendio. El área en color gris marca la posibilidad de ocurrencia del *flashover* inducido por ventilación y el *backdraft* indistintamente.

el capítulo 2 se revisan también investigaciones que han utilizado datos sintéticos obtenidos a partir de una simulación de fluidos computacional (CFD, *Computational Fluid Dynamics*).

### 1.3. Propuesta de solución

Esta tesis propone el desarrollo de un método que tiene como objetivo final la predicción del fenómeno *flashover* usando técnicas de inteligencia artificial. El método propuesto se centra en el humo que sale a través del hueco de ventilación, por lo que la predicción se realiza desde el exterior del recinto confinado usando una cámara de visión térmica. Esto daría solución al problema que tienen los miembros del equipo de intervención, que están en el interior del recinto, para evaluar la capa de gases de manera continuada debido a la carga de trabajo. Al liberar al personal actuante de esta tarea, esto permite que se centren en acciones como la extinción, búsqueda de personas o evacuación, mientras la situación es evaluada constantemente desde el exterior aumentando la efectividad en la predicción.



**Figura 1.5:** Sketch del método propuesto en esta tesis para la predicción del fenómeno *flashover*

En el caso del *backdraft*, una vez realizada la revisión del estado del arte en el capítulo 2, se llega a la conclusión (hasta donde se ha investigado) de que todavía es necesario realizar más estudios sobre las causas químicas y físicas que producen en este fenómeno, por esta razón este trabajo se ha centrado en la predicción del *flashover*.

#### 1.4. Objetivo general y objetivos específicos

La presente tesis tiene como objetivo general especificar un modelo predictivo capaz de determinar con antelación explosiones en incendios en espacios confinados, *flashover* y *backdraft*. Una vez completada la evaluación del estado de la cuestión, la investigación se centra en el *flashover* por lo motivos que se exponen en el punto anterior. El modelo requiere la utilización de secuencias de imágenes termográficas desde el exterior del espacio confinado. Además, se propone que el modelo esté basado en técnicas de aprendizaje para dotar de flexibilidad a los sistemas que pueden desarrollarse utilizando el mismo. Los objetivos específicos son:

- **Evaluar el estado de la cuestión** en relación con el modelado, la simulación y la predicción de los fenómenos *flashover* y *backdraft*.

- **Desarrollar una metodología para generar un conjunto de datos de imágenes sintéticas.** Se desarrollará una metodología para generar un conjunto de datos de imágenes sintéticas a partir de software de dinámica de fluidos computacional, que se espera que respalden la predicción de *flashover* en tiempo real utilizando técnicas de AI. Se utilizarán los parámetros técnicos de la cámara, técnica de tratamiento de imágenes y las ecuaciones de transferencia de radiación térmica para conseguir imágenes sintéticas que puedan ser utilizadas con fines predictivos. Con esto se pretende solventar la carencia de imágenes reales sobre este tipo de fenómenos obteniendo así los datos necesarios para realizar la predicción.
- **Desarrollar una metodología de validación y clasificación cuantitativa** del conjunto de datos de imágenes sintéticas con el objetivo de poder clasificar estas en los diferentes estados que podemos diferenciar en la curva de fuego. Se utilizarán dos experimentos reales a pequeña escala para validar los modelos propuestos. Se emplearán dos entradas diferentes de la imagen obtenida con la cámara térmica (ROI/IMAGEN) con el fin de crear dos conjuntos de datos de imágenes reales de cada experimento, que se compararán con las imágenes sintéticas generadas. Para realizar la validación y clasificación de los datos sintéticos se utilizará la distancia Wasserstein. Esta metodología pretende dar solución al problema que se plantea en la comparación con las imágenes sintéticas, ya que no siempre se va a poder mantener el área de interés (zona del humo en el exterior del recinto) en una intervención real. Según los datos obtenidos en la validación se usará el método con la técnica que mejor efectividad tenga.
- **Predecir el *flashover* en tiempo real** utilizando técnicas de inteligencia artificial aplicadas a TC. Para hacer esto se utilizarán los modelos ocultos de Markov (HMM) con diferentes vectores de características propuestos con el fin de encontrar el modelo óptimo. Los modelos se entrenarán utilizando los conjuntos de datos sintéticos obtenidos a partir de software de dinámica de fluidos computacional.

Para validar el modelo se llevarán a cabo dos experimentos reales a pequeña escala.

## 1.5. Estructura de la tesis

La tesis se estructura de la siguiente manera: en este capítulo **1** se ha realizado una introducción sobre el tema a tratar y se han expuesto la motivación, la propuesta y los objetivos que definen este trabajo; en el capítulo **2** se revisa el estado del arte de las técnicas de modelado y simulación de los fenómenos *flashover* y *backdraft*, comparación entre imágenes procedentes de CFD y TC y por último se revisan los trabajos de predicción; en el capítulo **3** se propone un método para crear una base de datos a partir de imágenes sintéticas y se realiza una validación de las imágenes obtenidas con el método propuesto. El método se centra en el fenómeno *flashover* debido a no haber encontrado conocimiento suficiente (hasta donde se ha investigado) sobre el fenómeno *backdraft*; en el capítulo **4** se propone un método para predecir el fenómeno del *flashover* utilizando técnicas de inteligencia artificial. Finalmente, en el capítulo **5** se exponen las conclusiones del trabajo de investigación.

En relación con la mención de doctor/doctora internacional y para ajustarse a la normativa vigente, en el apéndice **A** se ha incluido un resumen y conclusiones en inglés.

## 1.6. Convenciones de escritura

En el desarrollo de este trabajo de doctorado se utilizaron varios acrónimos para hacer referencia a diferentes métodos, técnicas y tecnologías a las que se hace referencia. El formato que se ha utilizado es escribir la primera vez aparece el término su definición y entre paréntesis el acrónimo. Por ejemplo, Organización de Naciones Unidas (ONU).

Se ha optado por usar algunos acrónimos en inglés ya que es así como comúnmente se utilizan en la literatura científica. Por ejemplo, Caracterís-

tica Operativa del Receptor (ROC, *Receiver Operating Characteristic*).

Las citas se reproducen en el idioma original de la referencia de donde provienen. Las Figuras y Tablas presentadas en este documento son de elaboración propia del autor, a menos que se indique lo contrario en el título.

Las cifras numéricas de miles están separadas por espacios y las cifras decimales están separadas por punto, siguiendo las normas internacionales.



Universitat d'Alacant  
Universidad de Alicante

# Estado del arte

---

En este capítulo se realiza una revisión para evaluar el estado de la cuestión. El capítulo está organizado en los siguientes apartados: la sección 2.1 presenta una breve introducción; en la sección 2.2 se presenta una revisión sobre las técnicas de modelado del *flashover* y *backdraft*; el apartado 2.3 analiza el estado del arte de la simulación de estos fenómenos; en el apartado 2.4 se revisa la comparación entre imágenes sintéticas e imágenes reales obtenidas con cámaras de imagen térmica; en la sección 2.5 se revisa la predicción de ambos fenómenos; finalmente, la sección 2.6 muestra las conclusiones de la revisión del estado del arte.

## 2.1. Introducción

Debido a la variedad de disciplinas que son necesarias dominar para poder llevar a cabo este trabajo, es necesario realizar una revisión del estado del arte de cada una de ellas por separado. Por una parte, se realiza la revisión del modelado de estos fenómenos. Esto implica revisar los trabajos que han investigado sobre la física y la química que envuelven la aparición de estas situaciones y qué experiencias se han llevado a cabo para entender estos fenómenos. La revisión de la simulación se centra en las herramientas y técnicas, informáticas y no informáticas, que se han utilizado para simular estos fenómenos. En el punto de comparación de imágenes, se han incluido trabajos que hacen validaciones entre imágenes sintéticas y reales en esta línea, haciendo hincapié en la transformación de la imagen sinté-

tica aplicando modelos de radiación de banda estrecha y parámetros de la cámara, debido a la complejidad física que conlleva. Por último, en la parte de predicción se incluyen trabajos en los que se han aplicado técnicas de inteligencia artificial para realizar predicciones relacionadas con un determinado fenómeno.

## 2.2. Técnicas de modelado

La ocurrencia de estos fenómenos está determinada por causas químicas y físicas. En esta línea, se han llevado a cabo investigaciones en incendios confinados para conocer los procesos, tanto físicos como químicos que se dan lugar en este tipo de situaciones. Por este motivo, se ha considerado interesante la inclusión de los trabajos previos más relevantes en esta área de investigación. Empezando con la investigación de Ingberg en 1928 [37] numerosos estudios en incendios confinados han sido llevados a cabo en las últimas décadas. La tabla 2.1 muestra los estudios más relevantes sobre incendios confinados desde 1928 hasta el presente, especialmente aquellos relacionados con los fenómenos *flashover* y *backdraft*.

### 2.2.1. Modelado del flashover

Estudios cuantitativos sobre el fenómeno *flashover* se llevaron a cabo por primera vez a mediados de los años 60 [77], desde entonces otros estudios han intentado formular pautas para la ocurrencia del *flashover* basados en diferentes simplificaciones [70]. Según los autores, debido a la complejidad de este fenómeno y considerando el *flashover* como el comienzo del incendio totalmente desarrollado, resulta más conveniente la consideración de un modelo simplificado y a su vez específico, que se desarrolla para este caso (*flashover*) a un enfoque más generalista. Babrauskas et al. [10] sugirió un modelo para la estimación de un posible *flashover* en un recinto determinando experimentalmente la ocurrencia de este fenómeno cuando la capa de gases alcanza temperaturas entre  $550^{\circ}\text{C}$ – $600^{\circ}\text{C}$  ( $823\text{ K}$ – $923\text{ K}$ ). El procedimiento sugiere la manera más simple para medir las tasas de pérdida de masa, es decir, en condiciones de combustión libre. Los resultados de este estudio revelan que la relación entre la tasa de pérdida de calor y la

Título	Fuente	Año	Autores & Referencias
Tests of the Severity of Building Fires	NFPA	1928	Ingberg et al. <a href="#">[37]</a>
Fire Behaviour In Rooms	Building research institute, Japan	1958	Kawagoe et al. <a href="#">[41]</a>
Room flashover—Criteria and synthesis	Fire Technology	1968	Waterman et al. <a href="#">[77]</a>
The Fire Resistance Required to Survive a Burnout	Fire Research Station	1970	Thomas et al. <a href="#">[72]</a>
Experimental Study of Small Enclosure Fire with Liquid Fuel	Japan Natural Resources Panel on Fire Research and Safety	1976	Takeda, Nakaya & Akita et al. <a href="#">[70]</a>
An Experimental Study of Flashover Criteria for Compartment	Stanford Research Institute	1979	Martin & Wiersma et al. <a href="#">[54]</a>
Flashover and Instabilities in Fire Behavior	Combustion and Flame	1980	Thomas, Bullen, Quintiere & McCaffrey et al. <a href="#">[71]</a>
Estimating Room Flashover Potential	Fire Technology	1981	Babrauskas et al. <a href="#">[10]</a>
Fire induced flows through room openings-flow coefficients	Symposium (International) on Combustion	1985	Steckler, Baum & Quintiere et al. <a href="#">[68]</a>
Quantitative Backdraft Experiments	Fire Safety Science	1994	Fleischmann, Pagni & Williamson et al. <a href="#">[25]</a>
Fires in compartments: the phenomenon of flashover	Royal Society	1998	Bishop & Drysdale et al. <a href="#">[15]</a>
Defining flashover for fire hazard calculations	Fire Safety Journal	1999	Peacock, Reneke, Bukowski & Babrauskas et al. <a href="#">[64]</a>
On the equations for flashover fire in small compartments	International Journal on Engineering Performance-Based Fire Codes	2001	Huo, Jin, Shi & Chow et al. <a href="#">[34]</a>
Combustion and heat transfer in compartment fires	Numerical Heat Transfer, Part A: Applications	2002	Yeoh, Yuen, Chen & Kwok et al. <a href="#">[83]</a>
Critical condition of backdraft in compartment fires: a reduced-scale experimental study	Journal of Loss Prevention in the Process Industries	2003	Weng & Fan et al. <a href="#">[79]</a>
Defining flashover for fire hazard calculations: Part II	Fire Safety Journal	2003	Babrauskas, Peacock & Reneke et al. <a href="#">[11]</a>
Experimental study of back-draft in a compartment with openings of different geometries	Combustion and Flame	2003	Weng et al. <a href="#">[78]</a>
On modelling combustion, radiation and soot processes in compartment fires	Building and Environment	2003	Yeoh, Yuen, Chueng & Kwok et al. <a href="#">[82]</a>
Heat fluxes and flame heights in façades from fires in enclosures of varying geometry	Proceedings of the Combustion Institute	2007	Lee, Delichatsios & Silcock et al. <a href="#">[51]</a>
An experimental study of the rate of gas temperature rise in enclosure fires	Fire Safety Journal	2011	Chen, Francis, Dong & Chen et al. <a href="#">[17]</a>
Defining the difference between backdraft and smoke explosions	Procedia Engineering	2013	Fleischmann & Chen et al. <a href="#">[24]</a>
An experimental study on backdraught: The dependence on temperature	Fire Safety Journal	2017	Wu & Carvel et al. <a href="#">[81]</a>

**Table 2.1:** Trabajos relevantes sobre dinámica del fuego en recintos confinados.

ocurrencia del *flashover* es significativa. No sólo la temperatura de la capa de gases está relacionada con la ocurrencia del *flashover*, el flujo de calor a nivel del suelo es otro factor a tener en cuenta en la aparición de este fenómeno. En una investigación llevada a cabo por Peacock et al., [64] se evaluaron las bases experimentales para las definiciones de los trabajos del *flashover*. Se presentaron comparaciones de los procedimientos de cálculo disponibles, que van desde correlaciones simples hasta modelos de incendio basados en simulaciones que se pueden usar para estimar el *flashover*. Se llegó a la conclusión de que el *flashover* puede ocurrir cuando la temperatura de la capa de gases alcanza  $\geq 600^\circ\text{C}$  o la radiación a nivel del suelo es  $\geq 20\text{ kW/m}^2$  dependiendo de los materiales, el recinto y el balance de masa y energía. En el siguiente caso de estudio realizado por Huo et al. [34], fueron llevados a cabo una serie de experimentos a escala real en un recinto confinado  $\leq 16\text{ m}^2$  con un tipo de combustible específico. En este trabajo se evaluó la influencia en la ocurrencia del *flashover* del área y la localización de las fuentes de ventilación (factor de ventilación) en el recinto. La ecuación resultante, que describe el *flashover*, se aplicó para conseguir un mejor diseño de establecimientos comerciales de reducido tamaño, mejorando la seguridad. Los autores se basaron en el modelo de dos capas para explicar que cuando ocurre el *flashover*, el incendio cambia de controlado por combustible a controlado por ventilación. En este estudio, los métodos empleados por — Kawagoe [41], Babrauskas [10], Thomas [71] and B. J. McCaffrey [55]— fueron también analizados y revelaron diferentes formas para hallar el valor de calor crítico para que el *flashover* tenga lugar. En la siguiente investigación [34], el factor de ventilación fue evaluado con un experimento en el que se estudiaron tres medidas diferentes de recipientes utilizando diésel como combustible. Para la realización del experimento se utilizó un recinto confinado de 4 m de longitud por 3 m de ancho por 3 m de alto. En la construcción del habitáculo se emplearon tableros de yeso de 7 mm de espesor para crear una estructura aislante de doble capa. El hueco de ventilación tenía unas medidas de 1.6 m de ancho por 2.2 m de alto. El resultado de los experimentos fue comparado con las ecuaciones propuestas anteriormente [10, 41, 55, 73]. El resultado de esta investigación fue una ecuación para calcular la tasa de liberación de calor (HRR, *Heat*

*Release Rate*) necesaria para que un *flashover* tenga lugar en un recinto de reducidas dimensiones, teniendo en el factor de ventilación para aberturas grandes.

Otro punto clave en la ocurrencia del *flashover* es la relación entre la tasa de calor liberado y el tiempo (HRR/s). Babrauskas et al. [11] llegó a la conclusión a través de un estudio de que esta relación determina la ocurrencia del *flashover*. En su trabajo empleó un contenedor estandarizado según la norma ISO 9705 (las dimensiones de este contenedor fueron  $2.4\text{ m} \times 3.6\text{ m} \times 2.4\text{ m}$  con una abertura de ventilación de  $0.8\text{ m} \times 2\text{ m}$ ), comparando los resultados de la experimentación con los datos obtenidos a través de simulaciones por ordenador. Los datos obtenidos, tanto de la experimentación como de las simulaciones, mostraron que intervalos cortos de tiempo asociados a la tasa de liberación de calor incrementaban la ocurrencia del *flashover*, puesto que como consecuencia también se incrementaban los valores de temperatura y el flujo de radiación. Este estudio considera que, en futuras líneas de investigación en recintos confinados, además del valor de HRR las condiciones y geometría de la llama, la capa de gases y las superficies del recinto deben de ser ampliamente definidas con objeto de profundizar en el conocimiento de fase anterior al *flashover* (*pre-flashover*). En los siguientes trabajos [82, 84] también se llegó a la conclusión de que los efectos de la radiación térmica son determinantes para realizar predicciones en la temperatura de la llama. Para llegar a este resultado, se analizaron diferentes configuraciones de recintos confinados (una, dos o más habitaciones en el mismo recinto) y los autores resaltaron la influencia que tiene la transferencia de calor a través de las paredes del recinto a la hora de realizar predicciones en incendios en espacios confinados. Se llegó también a la conclusión de que la radiación de hollín aumenta la radiación absorbida y emitida por los productos de combustión.

### 2.2.2. Modelado del backdraft

En relación con el modelado del fenómeno *backdraft*, Weng et al. [78, 79] llevó a cabo una serie de experimentos a pequeña escala para estudiar este fenómeno en un recinto confinado. Los autores llegaron a la conclusión de

que la fracción de masa de hidrocarburos está íntimamente relacionada con la sobrepresión que se genera en el interior del recinto. Valores más elevados de hidrocarburos dan lugar a mayores presiones en el interior del recinto por lo tanto el fenómeno *backdraft* tendrá una mayor intensidad. Los resultados dan a entender que la geometría de la posición de la abertura de ventilación fueron factores que tuvieron gran influencia en los tiempos de aparición de este fenómeno. Una vez más, con el objetivo de maximizar la eficiencia en coste y tiempo, los experimentos se llevaron a cabo en un recinto con un área total  $\leq 16 \text{ m}^2$  y siendo el número de experiencias realizadas en este trabajo 64. En este estudio se sugirió que la utilización de técnicas de dinámica de fluidos computacional (CFD, *Computational Fluid Dynamics*) combinadas con el uso de experimentaciones reales reduce los costes y acelerará el estudio del *backdraft*, debido al menor número de experimentaciones reales a realizar para estudiar este fenómeno.

En la misma línea, Wu and Carvel et al. [81] llevaron a cabo una serie de experimentos de escala reducida para investigar las condiciones de temperatura relacionadas con el *backdraft* en un incendio confinado. Se utilizaron pellets de plástico como combustible con una pequeña cantidad de n-heptano para ayudar a la ignición. Se llevaron a cabo noventa experimentos diferenciando entre “sin chispa” y “con chispa” y se asumieron diferentes tiempos para cerrar la abertura de ventilación. Finalmente, se llegó a la conclusión de que el *backdraft* es un fenómeno complejo el cual es posible predecir utilizando los datos de temperatura. La concentración de los gases no quemados y la temperatura del compartimento se presentan como factores críticos en la ocurrencia del *backdraft*. Además, para que el fenómeno *backdraft* se dé, por definición, es necesario que se produzca un cambio en la ventilación del recinto, pero en algunas circunstancias, es posible que aparezca en incendios confinados, un fenómeno similar sin que haya sido abierto ningún hueco de ventilación. Este fenómeno es conocido como explosión de humos y no debe ser confundido con un *backdraft*. En la investigación llevada a cabo por Fleischmann et al. [24], se expusieron las diferencias entre las explosiones de humo y el fenómeno de *backdraft*. Este estudio revela que puede ocurrir una explosión en un espacio confinado infraventilado sin un cambio en la ventilación disponible, donde la

única ventilación proviene de la fuga a través de las rendijas que pueda haber en el compartimento (por ejemplo, rendijas en puertas y ventanas cerradas). El fuego entra en un estado latente (brasas) y produce grandes cantidades de productos pirolizados y monóxido de carbono en exceso. La ignición ocurre cuando el gas combustible se combina con oxígeno y la mezcla de gases del compartimento alcanza el rango inflamable entrando en contacto con la fuente de ignición, enviando un frente de llama que se desarrolla rápidamente a través del recinto cuando el gas combustible se combina con oxígeno y la mezcla de gases del compartimento alcanza el rango inflamable.

La tabla 2.2 muestra un resumen de referencias citadas en esta sección. En esta tabla se pueden identificar las investigaciones relacionadas con el *flashover* y el *backdraft*, así como las técnicas más importantes empleadas en la investigación.

Ref	Flashover	Backdraft	Técnicas de investigación				
			Teóricas	Empíricas		CFD	Otras
				Escala reducida	Escala real		
41	x	x	✓	x	✓	✓	x
10	✓	x	✓	x	✓	x	x
64	✓	x	x	x	✓	✓	x
79	x	✓	✓	✓	x	x	x
11	✓	x	✓	x	✓	✓	x
78	x	✓	✓	✓	x	x	x
82	x	x	✓	x	✓	✓	x
24	x	✓	x	✓	x	x	x
81	x	✓	✓	✓	x	x	x
84	x	x	✓	x	✓	✓	x
88	x	x	x	x	x	x	x
23	✓	x	✓	x	✓	✓	✓

Tabla 2.2: Referencias sobre el modelado de los fenómenos *flashover* y *backdraft*

### 2.3. Simulación del flashover y backdraft

En el apartado 2.2, se ha puesto de manifiesto que los incendios confinados han sido estudiados extensamente por la comunidad científica es-

pecialista en esta área de conocimiento, con objeto de mejorar las técnicas de modelado. Es posible consultar numerosas investigaciones orientadas a mejorar sistemas de extinción, seguridad personal o el comportamiento de los materiales frente al fuego. También se ha planteado el problema que supone obtener datos de intervenciones reales de estos fenómenos y de los costos económicos y medioambientales de reproducirlos en determinadas condiciones. Por estas razones la mayoría de los estudios realizados han sido llevados a cabo en estructuras a pequeña escala. Para solventar este problema se ha propuesto la posibilidad de la utilización de datos sintéticos procedentes de simulaciones (ver secciones [1.3](#) y [3](#)) para poder aplicar técnicas de inteligencia artificial con objeto de realizar predicciones.

Mediante las simulaciones por ordenador es posible simular diferentes tipos de escenarios, parámetros como el tamaño del recinto, tipo de combustión, número y disposición de los huecos de ventilación y condiciones ambientales son variables que pueden ser modificadas. No obstante, este tipo de simulaciones tiene que estar supervisadas por personal experto que tenga un conocimiento profundo sobre el modelo y el comportamiento del fuego, de no ser así los datos obtenidos pueden ser erróneos [\[14\]](#).

Después de evaluar diferentes técnicas existentes relacionadas con la simulación de escenarios de fuego (correlaciones algebraicas, modelos de dos zonas o modelos de parámetros agrupados [\[1\]](#) y CFD o modelos de campo) finalmente se ha considerado revisar en este apartado modelos CFD. Los modelos de campo utilizan volúmenes discretos para aproximarse a un espacio real. A esto hay que añadir que son capaces de simular escenarios de incendios confinados complejos y se ha realizado una investigación considerable para validar diferentes modelos CFD. Teniendo en cuenta el tiempo empleado para realizar las simulaciones, la mayoría de los estudios revisados en este artículo han utilizado técnicas de dinámica de fluidos computacional para su investigación, incluida la técnica de simulación de grandes remolinos (LES, *Large Eddy Simulation*) (e.g., [\[33\]](#), [\[82\]](#)). LES tiene la capacidad de reducir el coste computacional ignorando las escalas de longitud más pequeñas, que son las más costosas de resolver

computacionalmente, mediante el filtrado de paso bajo de las ecuaciones de Navier-Stokes para capturar información esencial en el tiempo, pero la química del fuego y los procesos de formación y combustión de hollín deben resolverse para completar el modelo del fuego. El software CFD además brinda la posibilidad de obtener datos estructurados similares a los de una cámara térmica de visión. Por esta razón y dada su precisión de simulación, en este apartado se revisan las investigaciones más relevantes que utilizan esta tecnología incluyendo aquellas en las que los fenómenos *flashover* y *backdraft* han sido simulados.

### 2.3.1. Validación de modelos de campo

En relación con este tipo de simulaciones, se han llevado a cabo numerosas investigaciones para validar estas herramientas mediante la comparación de los resultados obtenidos con experimentos reales o modelos de diferentes tipos. En esta línea, en la siguiente investigación [18] realizada por Chow et al., se llevó a cabo una comparación entre modelos de zona y un modelo de campo a través de una simulación de un edificio con patio interior en Hong Kong. Se utilizaron 4 modelos de zona diferentes en este trabajo (FIRST, CFAST, CCFM.VENTS desarrollado por el Building and Fire Research Laboratories (NIST, *National Fire Protection Association*, USA) y el NBTC un modelo para recintos de una habitación de FIRE-CALC desarrollado por CSIRO, Australia). El modelo de campo utilizado fue desarrollado por los autores basado en las teorías de dinámica computacional de fluidos. Aunque para una rápida estimación del espesor de la capa de humo y la temperatura en el recinto pueden ser utilizados cualquiera de los modelos de zona mencionados anteriormente, el autor resalta el potencial de los modelos CFD sobre los de zona para ilustrar las simulaciones. A pesar de que el tiempo de simulación fue mayor en el caso de la simulación CFD, el análisis detallado del entorno térmico obtuvo una mayor precisión. En otro estudio, para validar diferentes modelos de campo Yeoh et al., llevó a cabo una serie de experimentos [82, 83, 84]. En uno de ellos [83], dos conjuntos de datos independientes (resultados numéricos de Lewis y medidas experimentales de Steckler) fueron empleados para validar predicciones cuantitativas obtenidas con Fire 3D (modelo CFD), sobre los

campos de velocidad y temperatura en un recinto confinado. Otro estudio de similares características fue abordado por Kumar et al. [9], que realizó una comparación entre los datos experimentales de Steckler [68] (los cuales han sido ampliamente utilizados como punto de partida para validar numerosos modelos de campo) y dos tipos de conjuntos de datos obtenidos con modelos CFD diferentes (ANSYS CFX-5 y Fire Dynamics Simulator (FDS)) para validar el modelo ANSYS CFX-5. Varios aspectos de las simulaciones fueron comparados y los resultados obtenidos desvelaron que los datos de la simulación con ANSYS CFX-5 concordaban razonablemente con los datos experimentales. El modelo de fuego proporcionó predicciones razonables de los campos de flujo térmico en condiciones de ventilación completa. El tiempo que empleó ANSYS CFX-5 para completar la simulación fue inferior al empleado por FDS. Como resultado de este estudio los autores llegaron a la conclusión de que la comprensión de la dinámica del fuego y los avances realizados en los métodos numéricos y el hardware tendrían un impacto significativo en el rendimiento de los modelos de fuego CFD en el futuro. En el siguiente trabajo, Zhao et al. [89] realizó simulaciones numéricas para investigar la precisión de FDS en incendios confinados con ventilación deficiente y llama externa a través del hueco de ventilación. Este estudio demostró la precisión de FDS [3] para calcular y reproducir esta clase de fenómeno. Los resultados obtenidos fueron validados con métodos diferentes, uno de ellos basado en la temperatura y el otro basado en la velocidad volumétrica de liberación de calor. Para llevar a cabo este estudio se realizaron 32 simulaciones con diferentes geometrías del recinto:  $0.1\text{ m} \times 0.2\text{ m}$ ;  $0.2\text{ m} \times 0.2\text{ m}$ ;  $0.2\text{ m} \times 0.3\text{ m}$ ; y,  $0.3\text{ m} \times 0.3\text{ m}$ . La precisión de los datos obtenidos fue discutida comparando los datos experimentales con correlaciones empíricas. FDS demostró capacidad para reproducir la altura del plano neutro, para distintas configuraciones, con un alto grado de precisión. A pesar de esto, los autores detectaron cierta incertidumbre a nivel de los datos experimentales, debido a que la HRR dentro del recinto no se pudo medir directamente.

### 2.3.2. Simulación del flashover

En referencia a la simulación del fenómeno *flashover*, se han encontrado varios estudios en los que se ha abordado este tema utilizando técnicas CFD. Como se ha comentado en el punto [2.2](#), FDS ha sido ampliamente validado y es capaz de realizar simulaciones con un alto grado de precisión. A esto hay que añadir que es una tecnología ampliamente utilizada al ser un software de licencia libre. En la siguiente línea, se ha realizado una revisión de aquellos trabajos en los que se ha utilizado esta tecnología para simular el *flashover*. Chow et al., llevó a cabo una investigación [\[19\]](#) para evaluar la precisión de FDS 3.01 a la hora de simular el fenómeno *flashover*. Se diseñaron una serie de experimentos a tamaño real para realizar la validación, tomando como guía para la construcción del recinto la norma ISO-9705 (Fire tests — Full-scale room test for surface products). Se utilizaron recipientes con gasolina de diferentes diámetros para proporcionar la tasa de liberación de calor necesaria para el experimento y haciendo uso del factor de ventilación, ambos parámetros fueron ajustados para producir el *flashover* en el interior del recinto. El criterio que se siguió para determinar si el *flashover* tenía lugar fue registrar una temperatura  $\geq 550$  °C 1 cm por debajo del techo y unos niveles de radiación  $\geq 20$  kW/m<sup>2</sup> a nivel del suelo. Una vez realizados los experimentos, los datos obtenidos fueron comparados con sus respectivas simulaciones del *flashover*. Los resultados fueron muy satisfactorios y se llegó a la conclusión de que FDS podía ser usado para simular esta clase de situaciones. Posteriormente, en el trabajo [\[52\]](#) de Mackay et al., fueron desarrollados una serie de modelos computacionales usando el código de FDS 5 para diseñar tácticas de entrenamiento para bomberos del servicio de bomberos NSW (Australia) en situaciones de *flashover*. En este caso el criterio seguido para determinar la ocurrencia del *flashover* fue, medidas de temperatura  $\geq 600$  °C obtenidas 1cm por debajo del techo del recinto, si bien, la tasa de liberación de calor a nivel de suelo no se tuvo en cuenta. El experimento a tamaño real se llevó a cabo en un contenedor de barco con unas dimensiones de 2.4 m  $\times$  12 m  $\times$  2.6 m, que son comúnmente utilizados por los bomberos para realizar sus entrenamientos. Se utilizaron paneles de madera como combustible y los experimentos se realizaron en un día de entrenamiento del servicio de

bomberos. Los resultados de la simulación coincidieron con los datos experimentales cualitativos. Hay que decir que con la simulación a partir de FDS se obtuvieron valores de temperaturas  $100\text{ }^{\circ}\text{C}$  más altos que en los experimentos, esto estaba dentro de lo esperado puesto que en la experimentación se incluyó la supresión del fuego por parte de los bomberos y en la simulación no. Otro interesante enfoque [85] lo encontramos en el trabajo de Yuen et al., en el que se llevó a cabo una investigación de la escena del incendio, en un centro de atención a personas mayores, utilizando técnicas CFD. En este estudio se usó el modelo de campo FDS 5.5.3 comparando los datos de las simulaciones realizadas con datos de experimentos a tamaño real. Para definir el comienzo de la fase del *flashover* se adoptó el criterio de obtener medidas de temperaturas  $\geq 600\text{ }^{\circ}\text{C}$  adquiridas 10 mm por debajo del techo y una tasa de liberación de calor aproximada mínima de 2175 kW, según el criterio de Thomas [71]. En total, seis casos distintos fueron simulados para investigar la posible localización de la fuente de ignición que pudo dar lugar al estado final de la escena. Los resultados obtenidos a partir de las simulaciones estaban en concordancia con los datos de los experimentos realizados y podían explicar el desarrollo del incendio en el interior del recinto. La propagación del incendio y el *flashover* fueron modelados con éxito por FDS. No obstante, el autor destaca que el problema de la escasez de datos cinéticos, el modelo de pirólisis FDS no puede representar completamente el comportamiento completo del fuego. En vista de lo expuesto anteriormente, Evergren et al. propuso un método [23] alternativo para determinar las temperaturas en un recinto confinado antes de que se produzca el *flashover* (fase *pre-flashover*). Después de comparar los resultados obtenidos con las simulaciones de FDS se comprobó que los tiempos para predecir las temperaturas usando la propuesta de Evergren et al. fueron inferiores a los de FDS. Por el contrario, este tipo de herramienta no permite observar el escenario como una imagen térmica detallada, similar a las obtenidas con TC.

### 2.3.3. Simulación del backdraft

En referencia al fenómeno *backdraft*, no se han encontrado tantas investigaciones como en el caso del fenómeno *flashover*. Teniendo en cuenta

que el *backdraft* es un fenómeno mucho más complejo que el *flashover*, la revisión realizada muestra que es posible simular este fenómeno utilizando técnicas CFD. En esta línea, una situación de *backdraft* [33] fue simulada por la Universidad de Lund utilizando un software CFD (ANSYS CFX) con la siguiente configuración: modelo turbulento de simulación de remolinos independientes (DES, *Detached Eddy Simulation*); un híbrido del modelo de simulación de grandes remolinos (LES); forma promediada de Reynolds de las ecuaciones de Navier-Stokes (RANS, *Reynolds-averaged form of the Navier-Stokes equations*); y el modelo de combustión de disipación de remolinos (EDM, *Eddy Dissipation Model*). Aunque es posible simular este fenómeno mediante técnicas CFD antes de que se produzca una abertura de ventilación, en este trabajo la simulación empieza en el momento en el que se abre un hueco de ventilación hasta que el *backdraft* desaparece dentro y fuera del compartimento. El recinto confinado fue inundado con una mezcla de  $CH_4$ , aire y productos procedentes de la combustión. La concentración de  $CH_4$  y  $O_2$  se comprobó durante el transcurso de la simulación en un pequeño volumen cilíndrico en la parte trasera del recinto confinado. Una vez que la mezcla entra en el rango de inflamabilidad, una fuente de energía térmica es aplicada temporalmente para provocar la ignición y comparar los resultados con los datos experimentales. Como resultado se obtuvieron diferencias en los tiempos simulados de ignición en comparación los datos experimentales de Gojkovic et al. [27]. Los tiempos calculados de ignición fueron inferiores a los tiempos observados en los experimentos. Los autores atribuyen este error al método experimental usado, en el que se identifica la ignición visualmente. Además de lo expuesto anteriormente, los autores resaltan que, para algunos casos idénticos de experiencias reales, el *backdraft* no ocurre siempre mientras que en las simulaciones sí. Esto ocurre porque el tiempo de ignición en las simulaciones está establecido, cuando la mezcla comburente combustible alcanza el rango de inflamabilidad. La mayor diferencia entrada ocurre para los valores de presión y temperaturas. En este caso, los autores atribuyen este error a: posibles deficiencias de los modelos de ignición y combustión; inexactitud en la predicción de la corriente de gravedad; y problemas de instrumentación en la experimentación. Aunque los autores consideran que el resultado es alentador, se

necesita más investigación para lograr una mayor precisión en los datos de presión y temperatura a fin de predecir este fenómeno correctamente. En el siguiente trabajo, Park, Oh, Choi and Han et al. simularon el fenómeno *backdraft* usando el software FDS [62]. Esta investigación prueba que es posible simular el *backdraft* utilizando el código original de esta herramienta incluyendo, simulación numérica directa (DNS, *Direct Numerical Simulation*) y modelos químicos de combustión finita. Las medidas utilizadas para diseñar el recinto confinado de esta simulación (modelo a escala reducida) están basadas en el trabajo de Weng and Fan et al. [79]. Las características que definen este fenómeno, como la ignición, la formación de llamas parcialmente premezcladas y la bola de fuego se modelaron correctamente. La conclusión de este trabajo es que es posible simular este fenómeno con FDS. Esta investigación fue continuada con un estudio computacional del *backdraft* [63] en un compartimento a escala reducida usando modelos de química finita y DNS. Se utilizaron dos tipos diferentes de modelos químicos de combustión (modelos de un paso y de tres pasos). El propósito de este trabajo es profundizar en el conocimiento de la dinámica del *backdraft* sin modificaciones del código original. Para ello se estudiaron distribuciones temporales de fracciones de masa, temperatura y presión. Para llevar a cabo esta investigación sobre la radiación térmica en el *backdraft*, se aplicó el modelo de radiación gris (modelo GRAY-GAS) y el modelo adiabático (ADIA, *adiabatic model*). La predicción de la ocurrencia del *flashover* se basó en la concentración de hidrocarburos en el interior del recinto. Los resultados fueron comparados con casos experimentales de los trabajos de Weng and Fan et al. [79] y Weng et al. [78]. Únicamente los resultados del modelo de químico de combustión de tres pasos se consideraron válidos. Los resultados de esta investigación muestran que los datos procedentes de las simulaciones pueden ser considerados razonablemente como una condición inicial de predicción para la ocurrencia del fenómeno *backdraft*. A pesar de que esta investigación prueba que es posible el uso de FDS para simular este fenómeno, es necesaria más investigación con diseños reales y configuraciones del recinto no simétricas. Esto ayudaría a desvelar las incógnitas sobre el tiempo de ignición, que está relacionado con el volumen del recinto confinado y la localización y tamaño de los huecos de ventila-

ción.

La tabla 2.3 muestra un resumen de las referencias citadas en este apartado relacionadas con la simulación de estos fenómenos. Es fácilmente identificable en la tabla si la referencia está relacionada con el *flashover* o el *backdraft*, así como las técnicas más importantes utilizadas y el software empleado para la simulación. La tabla también incluye si se han empleado TC en la investigación.

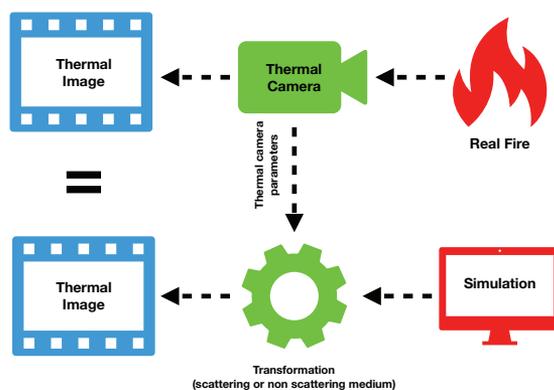
Ref	Flashover	Backdraft	Técnicas de investigación					Software CFD			TC
			Teóricas	Empíricas		CFD	Otras	FDS	ANSYS	Otro	
				Escala reducida	Escala real						
18	x	x	x	x	x	✓	x	x	x	✓	x
83	x	x	✓	x	✓	✓	x	x	x	✓	x
82	x	x	✓	x	✓	✓	x	x	x	✓	x
84	x	x	✓	x	✓	✓	x	x	x	✓	x
69	x	x	✓	✓	x	✓	✓	✓	x	x	✓
9	x	x	x	x	x	✓	x	✓	✓	x	x
19	✓	x	x	x	x	✓	x	✓	x	x	x
52	✓	x	x	x	✓	✓	x	✓	x	x	x
23	✓	x	✓	x	✓	✓	x	✓	x	✓	x
89	✓	x	✓	✓	x	✓	x	✓	x	x	✓
85	✓	x	x	x	✓	✓	x	✓	x	x	x
33	x	✓	x	x	✓	✓	x	✓	✓	x	x
62	x	✓	✓	✓	x	✓	✓	✓	x	x	x
63	x	✓	✓	✓	x	✓	✓	✓	x	x	x

Tabla 2.3: Referencias sobre la simulación de los fenómenos *flashover* y *backdraft*

## 2.4. Sintetizado y comparación de imágenes

La elaboración de un conjunto de datos, obtenido a partir de simulaciones, que pueda ser utilizado en labores de predicción en una cámara de visión térmica requiere de métodos de validación. Ha de asegurarse de que las imágenes sintéticas son similares a las obtenidas con TC. Pero previamente a este paso es necesario realizar un renderizado para poder obtener las imágenes sintéticas a partir del software CFD. El renderizado de imágenes a partir de un software CFD y comparar estas con imágenes TC supone utilizar el uso de diferentes técnicas que deben ser tratadas de manera por separado. Por esta razón, en este apartado se revisan en primer lugar las técnicas de renderización utilizadas en esta línea. En segundo lugar, se presenta el estado del arte sobre la comparación de imágenes.

Para la obtención de imágenes a partir de simulaciones y poder comparar estas con las imágenes obtenidas con una TC, se han de tener en cuenta varios factores. En primer lugar, los parámetros de la cámara, como el campo de visión (FOV, *Field of View*) o la resolución, tienen que ser consideradas para obtener el área de interés correcta en la simulación. Además de lo anterior, el rango espectral de la cámara térmica tiene que ser incluido en los cálculos. En segundo lugar, el diseño de la simulación es determinante en la exactitud de los datos obtenidos. Por esta razón, es necesario una transformación (ver figura 2.1) de los datos simulados, incluyendo todos los parámetros mencionados, para obtener una imagen lo más similar posible a la de la cámara de imagen térmica.



**Figura 2.1:** Secuencia de transformación de la imagen

En esta línea, Rankin et al., [67] presenta un modelo para la obtención de imágenes, a partir de simulaciones, utilizando el espectro de radiación del infrarrojo medio. En este trabajo, se utilizó LES para llevar a cabo la simulación. El campo de flujo de reacción de una llama turbulenta no premezclada se calculó usando un código LES con número de Mach bajo de densidad variable y con una variable de llama/progreso extendida (FPV, *flamelet/progress variable*). Se utilizó el procedimiento dinámico de Smagorinsky para modelar los flujos turbulentos de la subred. El flujo escalar

turbulento se modeló invocando un transporte de gradiente asumido, y la tasa de disipación escalar residual se modeló utilizando argumentos espectrales. Para este caso específico, se utilizó el límite ópticamente delgado para modelar la tasa de pérdida de calor por radiación. Se consideraron las contribuciones de radiación de  $CO_2$ ,  $CO$ ,  $H_2O$  and  $CH_4$  y se utilizó un modelo de radiación de banda estrecha (RADCAL) para calcular los valores medios de los coeficientes de absorción de Planck. Los resultados de esta simulación se recopilaron en un dominio cilíndrico discretizado con aproximadamente 5.53 millones de volúmenes. Al establecer esta configuración en la simulación, las imágenes dependientes y promediadas en el tiempo de la intensidad de la radiación emitida por la llama turbulenta no premezclada, se renderizan utilizando los resultados escalares obtenidos con LES, un modelo de radiación de banda estrecha y la solución a la ecuación de transferencia radiación. Se usaron conjuntamente los datos de temperatura y las fracciones molares de  $CO_2$  y  $H_2O$  con el modelo de radiación de banda estrecha (RADCAL) para calcular los coeficientes espectrales. En este estudio, fueron propuestos tres casos diferentes en lo que se refiere a LES: i) excluyendo las contribuciones de la radiación de  $CO_2$ ,  $CO$ ,  $H_2O$  y  $CH_4$  en el cálculo de la tasa de pérdida de calor; ii) incluyendo esta última contribución; y, iii) incluyendo la contribución de la radiación y los efectos de la flotabilidad. Finalmente, los tres casos fueron comparados con los valores medidos a través de la experimentación como con los valores corregidos obtenidos a partir de la simulación.

Se han utilizado diferentes técnicas para comparar imágenes de cámaras térmicas con imágenes obtenidas de simulaciones de incendios. En este contexto, el propósito final de la investigación determina la precisión del método elegido. A continuación, se revisan los trabajos que han utilizado diferentes métodos con buenos resultados.

En el siguiente trabajo, Shudheer et al., [69] empleó una cámara de imagen térmica para la medición de distribuciones de temperatura en fuegos de recipientes circulares que contenían gasolina como combustible, comparando los resultados con simulaciones en FDS. Para realizar la comparación se

colocaron termopares distribuidos a lo largo de la línea central de la llama para poder comparar los resultados con los obtenidos en FDS, verificando así que el modelo de combustión se había diseñado correctamente. Para validar FDS en la simulación de llamas de difusión, el autor resalta la importancia de construir un plano central que contenga una distribución de temperatura y emisividad de los datos obtenidos con TC. La justificación de esto último es, porque una cámara infrarroja únicamente puede observar la radiación total de la llama, pero no puede detectar únicamente un plano central para poder comparar las imágenes con las confeccionadas a partir de los datos de la simulación, por esta razón es necesario realizar una transformación (ver Figura 2.1). La técnica del modelo de radiación de banda estrecha y las ecuaciones de transferencia de radiación se utilizaron para este propósito en esta investigación. Finalmente, las simulaciones numéricas fueron validadas utilizando los datos experimentales del flujo de radiación y las imágenes proporcionadas por la cámara térmica. En las siguientes investigaciones [40, 61, 66, 67], se llevaron a cabo estudios de comparación entre imágenes simuladas e imágenes obtenidas con TC. Los estudios se centran en diferentes tipos de llamas, difusión y pre-mezcla. Para realizar la transformación de la imagen los autores utilizan también la técnica del modelo de banda estrecha en combinación con las ecuaciones de transferencia de radiación. En estos trabajos se adoptan diferentes modelos de combustión para validar su precisión a la hora de obtener las imágenes sintéticas. Finalmente, se llegó a la conclusión de que las imágenes térmicas obtenidas con la cámara y las sintéticas presentaban similares características cualitativas. En la siguiente investigación llevada a cabo por Johnson, Wu y Ihme et al., [38] se propuso un enfoque probabilístico general para la evaluación cuantitativa de los modelos de combustión LES. En este estudio, se utilizó la distancia Wasserstein (WD, *Wasserstein Distance*) para realizar una reconstrucción probabilística utilizando datos experimentales. El método se aplicó en llamas de chorro parcialmente premezcladas calculadas usando LES. Como resultado, se categorizaron los errores que surgen de las deficiencias en la especificación de las condiciones de contorno y las limitaciones intrínsecas de los modelos de combustión.

En este apartado, se ha revisado el renderizado de imágenes sintéticas y la comparación entre estas y las imágenes obtenidas con cámara de visión térmica. Los trabajos revisados sugieren que es posible transformar las imágenes de CFD, usando las especificaciones de una determinada cámara térmica, para obtener imágenes similares a esta. En referencia a la comparación de imágenes, se han utilizado diferentes técnicas en los artículos analizados, siendo la distancia WD una novedosa técnica aplicada a entornos de combustión con resultados más que aceptables.

## 2.5. Predicción del flashover y backdraft

En este apartado se muestran los estudios más relevantes, relacionados con la predicción de este tipo de fenómenos, que han sido llevados a cabo utilizando redes neuronales. Han sido incluidas también aquellas investigaciones que han usado esta tecnología para predecir algunos aspectos relacionados con el fuego, incluyendo las que están orientadas a la predicción del *flashover* o *backdraft* sin incluir cámaras de imagen térmica.

En esta línea, Huseynov et al. lleva a cabo una investigación [35, 36] para la detección de llamas usando redes neuronales. Se utilizó el análisis conjunto de tiempo-frecuencia (JTFA, *Time-frequency Joint Analysis*) con una transformada de Fourier de tiempo reducido para extraer información relevante. Este estudio se centró en el dominio de la frecuencia de la señal, debido a que las señales que emite una fuente de fuego pueden variar en amplitud y función dependiendo de la distancia, ángulo, presencia de obstáculos y otras fuentes que no son generadores de llama (sol, viento, modulación aleatoria, luces brillantes, lluvia, niebla, polvo, etc.) que pueden parecer llamas a los ojos de un sensor de infrarrojos. En contraste con el dominio del tiempo, la frecuencia de parpadeo de una llama permanece relativamente independiente de las diferentes condiciones ambientales. Debido a la cantidad de varios falsos positivos que pueden ocurrir, se consideró utilizar una red neuronal múltiple en lugar de una gran escala. Este modelo se montó en un procesador de señal digital (DSP, Texas Instruments (TI) F2812), llegando a la conclusión de que la respuesta a la detección de

una llama de este modelo es igual o mayor que algunos de los sistemas de detección actuales. Otro enfoque es el que podemos encontrar en la investigación realizada por Won-Ho Kim et al. [44]. Su investigación se basa en la predicción mediante el estudio de los píxeles vecinos de un vídeo, proporcionado por TC. Finalmente, el autor propone un sistema de detección de llama basado en un algoritmo optimizado con un procesador de señal digital para optimizar el tiempo de detección, entre 5 y 20 segundos.

La predicción de parámetros en incendios confinados es un enfoque alternativo extremadamente rápido. En esta línea, se han desarrollado varias ANN en lugar de usar técnicas CFD, que necesitan más tiempo computacional para hacer el mismo trabajo. En los casos que se muestran a continuación, se utilizaron técnicas CFD para validar la ANN. En la siguiente investigación, Lee et al., [50] desarrolló un nuevo modelo de ANN (GRNNFA) para predecir las ubicaciones de las interfaces térmicas. Para entrenar y evaluar la ANN, fueron utilizados los datos de 55 experimentos realizados por Steckler et al. [68] (con diferentes ubicaciones de fuego, intensidades de fuego y tamaños de puertas y ventanas). Debido a los efectos de difusión y mezcla del flujo de fluido, la altura térmica no se pudo determinar con precisión. Para estos casos, se utilizó FDS para validar la ANN realizando una simulación de los datos experimentales. Cuando se compararon las simulaciones con los datos experimentales, los autores llegaron a la conclusión de que FDS no predijo consistentemente (los valores de los resultados fueron más bajos de lo previsto) los resultados experimentales de la altura de la interfaz térmica. Por esta razón, se promedió la diferencia absoluta, y este factor de corrección se aplicó para el entrenamiento de la red neuronal. Los resultados predichos por GRNNFA de los 55 casos se compararon con los resultados de las simulaciones y se llegó a la conclusión de que el GRNNFA puede predecir las ubicaciones de las interfaces térmicas dentro del rango de los resultados experimentales con una precisión de hasta un 94.5% (es decir, solo 3 de las 55 muestras se predijeron fuera del rango de rango). El modelo anterior se aplicó a cinco casos de prueba que no aparecían en los experimentos y los resultados se compararon con simulaciones FDS. Posteriormente, se encontró que la diferencia entre las

predicciones y las simulaciones está dentro del rango de error mínimo. A lo anterior hay que añadir que el GRNNFA pudo capturar de manera eficiente las características genuinas y predominantes de los fenómenos que se dan en incendios en segundos a partir de muestras limitadas. Esta ANN se aplicó para predecir el fenómeno de *flashover* en incendios confinados [47] basándose en la geometría del compartimento.

En relación con la predicción del *flashover*, Lee et al., desarrolló un nuevo modelo de ANN [49], utilizando un mapeo probabilístico con máxima entropía (PEmap). Este modelo se utilizó como clasificador binario para predecir la ocurrencia de este fenómeno en incendios de un solo compartimento y los resultados se compararon y verificaron con los datos obtenidos por Fuzzy ARTMAP (FAM). Se utilizó un paquete informático (FAST [2]) para introducir un criterio de *flashover* (temperatura de la capa superior de gases  $\geq 600\text{ }^{\circ}\text{C}$ ) para predecir el *flashover*. Debido a la imposibilidad de obtener suficientes datos de emergencias reales, el entrenamiento del modelo se realizó mediante datos obtenidos a partir de simulaciones. Concretamente, se llevaron a cabo 375 simulaciones (190 muestras de *flashover* y 185 sin *flashover*) para entrenar el modelo PEmap, variando aleatoriamente diferentes parámetros del compartimento:

- Longitud del compartimento (varía aleatoriamente de 2 a 10 metros)
- Ancho del compartimento (varía aleatoriamente de 2 a 10 metros)
- Altura del compartimento (varía aleatoriamente de 2 a 10 metros)
- Tasa máxima de liberación de calor (varía aleatoriamente de 10 a 6 000  $kW$ )

Posteriormente, FAST determinó la ocurrencia del *flashover* para diferentes combinaciones de las dimensiones del recinto y tasa máxima de liberación de calor. Aunque los resultados de la predicción muestran que PEmap es una herramienta de clasificación eficiente para la determinación de *flashover*, con un alto grado de precisión (96.8%), el modelo de red neuronal no se implementó en ningún dispositivo (por ejemplo, una TC)

para ser probado en un caso real.

En un estudio mostrado anteriormente [50] se aplicó el modelo GRNN-FA para predecir la ubicación de la interfaz térmica en un incendio de un solo compartimento. Se demostró que el rendimiento de este ANN es comparable al del modelo CFD, además, la velocidad de cálculo del GRNNFA fue más rápida que el modelo CFD. GRNNFA presentó algunas limitaciones debido a que restringe los resultados en el área de aplicación del modelo. A esto último hay que añadir que, Yuen et al. [86] presentó una modificación del modelo GRNNFA original para problemas de predicción multidimensional y se utilizó con éxito para predecir los perfiles de velocidad y temperatura en el centro de la puerta en un incendio de un solo compartimento. Hubo algunos problemas con la aplicación de esta técnica en la región local porque las muestras de entrenamiento en esa región pueden no ser suficientes para describir el comportamiento general del sistema. Finalmente, este modelo se aplicó para predecir el *flashover* bajo los parámetros de fuego dados (largo, ancho, alto y tasa máxima de liberación de calor). Se concluye que este modelo es estadísticamente superior a los modelos Fuzzy ARTMAP y PEmap [45]. Por el contrario, en una situación real de *flashover*, no es posible introducir parámetros de un espacio confinado en un dispositivo TC. Esto es debido a que la velocidad de los eventos que se van sucediendo es muy alta y a esto hay que añadir la imposibilidad de conocer las dimensiones exactas del recinto. En esta línea, las técnicas de reconocimiento de imágenes podrían ser una tecnología útil para resolver este problema. Otro enfoque distinto para predecir la localización de la interfaz térmica en un incendio confinado es el estudiado por Lee et al., [48] en su trabajo. Se utilizó un modelo de red neuronal basado en la entropía probabilística (PENN) como alternativa a la técnica CFD, puesto que requiere un menor coste computacional para un caso de estudio. El modelo PENN fue utilizado para la predicción del (HTI, *Height of Thermal Interface*) dentro de un incendio confinado utilizando datos experimentales reales. El análisis estadístico de los resultados demostró positivamente la precisión del modelo PENN en un incendio confinado, siendo el tiempo de cálculo invertido en la predicción del HTI es mucho mejor que el empleado

con técnicas CFD. Por otro lado, los autores aclaran que, si bien el uso de esta técnica es alentador, se necesitan nuevas líneas de investigación para profundizar en la determinación del radio inicial del kernel, pues estos han sido determinados empíricamente para este estudio.

En una emergencia relacionada con un incendio confinado, el tiempo de respuesta es crucial para prevenir una situación peligrosa, por esta razón las predicciones tienen que ser realizadas en tiempo real. Las siguientes investigaciones incluyen técnicas de aplicaciones en tiempo real para predecir ciertas situaciones relacionadas con incendios confinados. Kacem et al., [39] desarrolló una pequeña red neuronal para predecir la propagación del fuego a bordo de buques de guerra. A pesar de que el propósito de esta investigación no es la predicción del *flashover*, se tuvo en cuenta para evaluar el compartimiento del fuego y decidir si será crucial para la propagación del fuego a otro recinto. Para determinar la aparición del fenómeno *flashover* se evaluó la tasa de pirólisis en el compartimiento y se calculó la duración de la fase completamente desarrollada, usando fórmulas empíricas para una combustión limitada por combustible y una combustión limitada por ventilación. Finalmente, se realizaron experimentos a gran escala en un contenedor de fuego con múltiples compartimentos usando ventilación mecánica. Para validar el modelo se utilizó una simulación CFD y determinar de esta manera la probabilidad de propagación de un incendio en una embarcación con una configuración específica. A pesar de que el estudio llega a la conclusión de que la tasa de pirólisis predice la aparición de *flashover*, no se puede considerar este valor para predecir estas situaciones con TC. En relación con TC, Kim et al. propone un método [43] para la búsqueda del fuego en espacios confinados llenos de humo usando imágenes térmicas diseñadas para SAFFIR (Robot autónomo de extinción de incendios en barcos). Se basa en un estudio anterior [42] en el que se utilizó una clasificación probabilística para el fuego, el humo, sus reflejos térmicos y los objetos calientes utilizando la teoría bayesiana. El punto clave es que, para la clasificación de fuego y humo, se utiliza una técnica de imagen basada en clústeres para discriminar las dos clases, primer plano (objetos) y fondo, lo que resulta en un cálculo rápido durante la

implementación en tiempo real. A pesar del resultado obtenido, este método se utiliza dentro del recinto con todos los riesgos que esto implica. Otro enfoque que obtenga datos del humo en el exterior del recinto con una cámara térmica podría proporcionar información relevante sobre el desarrollo del fuego. En un estudio reciente [87], se utilizaron Redes Generativas Antagónicas Condicionales para predecir el rápido crecimiento del fuego (*flashover*) en tiempo real. Se utilizó una cámara corporal estándar para analizar el vídeo en color y los patrones de humo y fuego muy oscuros se mejoraron aplicando redes neuronales generativas antagónicas. Previo a este paso, fue aplicada una técnica de conversión imagen-imagen, usando redes generativas antagónicas para obtener una imagen térmica a partir de una imagen en color. El entrenamiento y la prueba de la red neuronal se llevaron a cabo utilizando 30 y 10 vídeos proporcionados por dos departamentos de bomberos diferentes, prediciendo el *flashover* 55 segundos antes de que este ocurriera. Aunque esta tecnología se desarrolló a partir de imágenes en color, los autores señalan que es posible aplicarla sobre imágenes térmicas de TC para predecir situaciones de *flashover*. Como se ha comentado anteriormente, los conjuntos de datos de entrenamiento y prueba de situaciones reales son limitados por lo que sólo es posible analizar algunos casos con configuraciones simples como contenedores de fuego (usados en prácticas por los bomberos). El software CFD combinado con técnicas de transformación de la imagen, podría ser una herramienta interesante para generar conjuntos de datos con diferentes configuraciones y combustibles para entrenar redes neuronales a partir de imágenes de TC.

La tabla [2.4] muestra un resumen de las referencias relacionadas con la predicción que han sido citadas en este apartado. Es posible identificar fácilmente en la tabla si la referencia está relacionada con el *flashover* o *backdraft*, cuáles son las técnicas más importantes empleadas, el tipo de software usado en las simulaciones y si se ha empleado TC en el estudio.

Ref	Flashover	Backdraft	Técnicas de investigación		Software CFD			Sensores	TC
			ANN	Otras	FDS	ANSYS	otro	Infrarrojos	
35	x	x	✓	✓	x	x	x	✓	x
36	x	x	✓	✓	x	x	x	✓	x
45	x	x	✓	x	x	x	x	✓	x
44	x	x	x	✓	x	x	x	x	✓
48	x	x	✓	x	x	x	x	x	x
86	x	x	✓	x	x	✓	x	x	x
49	✓	x	✓	x	x	x	✓	x	x
47	✓	x	✓	x	x	x	✓	x	x
50	x	x	✓	x	✓	x	x	x	x
44; 43	x	x	✓	x	x	x	x	✓	✓
87	✓	x	✓	x	x	x	x	x	x
39	✓	x	✓	x	✓	x	✓	x	x

**Tabla 2.4:** Referencias sobre la predicción de los fenómenos *flashover* y *backdraft*

## 2.6. Conclusiones

En este capítulo se han revisado las técnicas más novedosas utilizadas para el modelado, simulación y predicción de fenómenos de *flashover* y *backdraft* en incendios confinados. En lo que respecta al modelado y la simulación, se han revisado los estudios más recientes de *flashover* y *backdraft*. Si bien los artículos analizados describen un profundo nivel de conocimiento sobre estos fenómenos, existen algunos temas que requieren una mayor exploración, especialmente en el contexto del fenómeno del *backdraft*.

Las investigaciones llevadas a cabo sobre el *flashover* indican un profundo grado de conocimiento. Hay algunos aspectos que determinan la aparición del fenómeno de *flashover*, especialmente la temperatura superior de la capa de gases  $\geq 550\text{ }^{\circ}\text{C}$  ó  $\geq 600\text{ }^{\circ}\text{C}$  (según el estudio analizado) y el flujo de calor al nivel del suelo  $\geq 20\text{ kW/m}^2$ . Ambos factores deben considerarse para definir el punto inicial de esta fase de transición hacia un incendio completamente desarrollado. Además, el factor de ventilación tiene un impacto vital en la ocurrencia de *flashover* debido a que, la ubicación y el tamaño del hueco de ventilación mantiene una estrecha relación con el desarrollo de este tipo de fenómenos. La identificación del hueco de ventilación mediante técnicas de visión artificial [75] en tiempo real podría proporcionar información valiosa para predecir el *flashover*. Además,

el *flashover* está claramente determinado por una relación entre la tasa de liberación de calor en un tiempo determinado (HRR/time), lo que podría ser un tema clave para la predicción con modelos ANN. Con relación al *backdraft*, son necesarios más estudios para diferenciar el este último de las explosiones de humo (fenómeno que puede ocurrir en diferentes situaciones). Además, se necesita un mayor conocimiento sobre la concentración de especies que participan y los hidrocarburos no quemados involucrados en la aparición de este fenómeno. Una nueva investigación sugiere que es posible predecir y evitar el *backdraft* mediante el uso de datos de temperatura.

La revisión de simulaciones a partir de modelos matemáticos revela que en la actualidad la simulación de dinámica de fluidos computacional (CFD) predomina sobre otros modelos analizados. Siendo una de las muchas ventajas de este tipo de simulación el análisis detallado de ambientes térmicos, que se puede utilizar para entrenar y validar ANN con cierta precisión. Entre los diferentes tipos de software CFD analizados en esta revisión, podemos observar que FDS ha sido utilizado para llevar a cabo diferentes investigaciones. Además de haber sido validada ampliamente, al igual que otras herramientas similares (Ansys CFX), el uso de FDS está ampliamente extendido debido a que se trata de una herramienta gratuita y de código abierto. A esto hay que añadir que el fenómeno *flashover* ha sido simulado con FDS con gran precisión. Por el contrario, no ocurre lo mismo con el *backdraft*, debido a que se han encontrado dificultades a la hora de la simulación. Independientemente del software utilizado, la mayor dificultad encontrada en la simulación del *backdraft* radica en que se ha utilizado simulación numérica directa (DNS, *Direct Numerical Simulation*). Esto quiere decir que, el usuario predefine una serie de parámetros (mezcla combustible-comburente, productos no quemados en suspensión, ignición, etc) para que el *backdraft* tenga lugar. Esto presenta un problema para emplear este tipo de simulaciones para crear una base de datos sintética de este fenómeno. Dado que, como se ha visto durante la revisión, hay casos en los que en la simulación se produce el *backdraft* pero en la experimentación real del mismo caso no se produce.

Respecto a las cámaras de imagen térmica, es importante resaltar que según los artículos revisados no es posible comparar los datos procedentes de las simulaciones FDS con los datos obtenidos directamente con la cámara. Es necesario realizar algunas transformaciones antes de este paso, pues la imagen final depende de los parámetros técnicos de la cámara térmica y de las condiciones del medio. Esto debe tenerse en cuenta para el desarrollo de tecnología de inteligencia artificial basada en cámaras de imagen térmica si queremos utilizar técnicas CFD para entrenar a las ANN. Es posible utilizar técnicas de programación y visión artificial para realizar los cálculos matemáticos y lograr el objetivo final.

En cuanto a la predicción mediante AI, esta revisión muestra que existen diferentes líneas de investigación que cubren el *flashover* pero no en relación con el fenómeno *backdraft*. Se pueden observar diferentes modelos de predicción, con las líneas predominantes orientadas a AI y redes neuronales. Los modelos ANN se han desarrollado para predecir incendios, la ubicación de la interfaz térmica en un compartimiento de incendios (HTI, *Heat Termal Interface*) o cuándo ocurre el *flashover*. No obstante, no hay investigaciones que involucren técnicas de inteligencia artificial para predecir el *backdraft*. Además, no se ha encontrado ningún documento que discuta la utilización de AI en cámaras de imagen térmica para predecir el *flashover* o el *backdraft* utilizando un conjunto de datos sintéticos creados a partir de software CFD. En los casos analizados, los conjuntos de datos, utilizados para predecir la ocurrencia de *flashover*, se basaron en la información de los sensores en la simulación. Sin embargo, podrían utilizarse otros parámetros de los modelos de campo (por ejemplo, relaciones entre los datos de los sensores interiores y las imágenes obtenidas) con el fin de crear un conjunto de datos para entrenar modelos de ANN basados en TC.

En relación al fenómeno de *flashover*, no se han evaluado escenarios reales complejos con diferentes huecos de ventilación y combustibles. En la mayoría de los casos analizados, se han utilizado experimentos a escala reducida, con configuraciones simples, para estudiar este fenómeno. Si bien, para determinar la ocurrencia del *flashover*, no solo es necesario considerar

la temperatura de la capa de gas y la radiación del flujo de calor a nivel del suelo, también hay que tener en cuenta el factor de ventilación y la HRR/tiempo. Por este motivo, es necesario analizar otras configuraciones del recinto confinado. Aunque el *flashover* es simulado de manera muy precisa utilizando diferentes programas de CFD, es difícil encontrar tales simulaciones con el fenómeno de *backdraft*, lo que subraya el desafío de realizar más investigaciones para simular correctamente este fenómeno. Con relación a esto, es necesario investigar los aspectos químicos y físicos del *backdraft* para adquirir un conocimiento profundo de este tipo de fenómenos, como el aporte de los hidrocarburos sin quemar a partir de diferentes combustibles. Esto ayudaría a simular de una manera más precisa este tipo de fenómenos evitando usar DNS.

Se identificaron algunas investigaciones con respecto a la predicción de *flashover* utilizando ANN, pero no se han encontrado trabajos que predigan este fenómeno con cámaras de imagen térmica, utilizando conjuntos de datos obtenidos con software CFD para entrenar ANN. Además, las cámaras térmicas de visión pueden ser dispositivos útiles para predecir el *flashover* por los servicios de bomberos teniendo en cuenta la investigación analizada, puesto que se pueden desarrollar nuevos modelos de predicción centrándose en imágenes térmicas en tiempo real. Por el contrario, no se han encontrado investigaciones sobre la predicción de *backdraft* utilizando ANN.

Teniendo en cuenta las diferentes áreas estudiadas y analizadas en este capítulo, se concluye que el fenómeno de *flashover* ha sido suficientemente estudiado para ser modelado y simulado utilizando configuraciones simples. Además, se han utilizado técnicas de AI para predecir su ocurrencia utilizando sensores colocados dentro del recinto. Por todo esto, se llega a la conclusión de que existe suficiente conocimiento para llevar a cabo una investigación sobre la predicción del *flashover* en relación a la propuesta del capítulo [1.3](#). No ocurre lo mismo con el fenómeno *backdraft*, después del análisis del estado del arte se concluye que no hay suficiente conocimiento (hasta donde se ha investigado) sobre este tipo de fenómeno. Esto

último se manifiesta en las simulaciones analizadas, en vista de que por su complejidad es necesario el uso de DNS para que el *backdraft* pueda producirse. Por esta razón, la tesis finalmente se centra únicamente en la predicción del fenómeno *flashover*.



Universitat d'Alacant  
Universidad de Alicante



Universitat d'Alacant  
Universidad de Alicante

# Modelado de la imagen térmica

---

Este capítulo se centra en los métodos propuestos para la generación y validación de conjuntos de datos sintéticos para poder utilizarse en la predicción del flashover. La estructura del capítulo es la siguiente: en el apartado 3.1 se subrayan los aspectos más importantes de los capítulos anteriores y se introducen los trabajos que se van a realizar; en la sección 3.2 se desarrolla el método propuesto para la generación de un conjunto de datos sintético; el apartado 3.3 expone el método propuesto de validación y clasificación del conjunto de datos sintético; en la sección 3.4 se presentan el método experimental y los experimentos llevados a cabo en este trabajo, así como el material utilizado; el apartado 3.5 muestra los puntos claves de cada apartado y se discuten los resultados obtenidos; finalmente, en la sección 3.6 se exponen las conclusiones.

## 3.1. Introducción

A continuación, se expone un resumen de los puntos claves que se han extraído de los capítulos anteriores, así como una breve introducción de los métodos propuestos en este capítulo.

Dependiendo de la disponibilidad de oxígeno en el recinto podíamos

tener diferentes situaciones, FC y VC, dependiendo de si este dispone suficiente de ventilación o no. Conviene recordar que, si existen deficiencias de oxígeno el fenómeno *flashover* puede aparecer después de un cambio en la ventilación, *flashover* inducido por ventilación (ver figura 1.4a). Además de esto, es necesaria una cantidad mínima de combustible, para alcanzar las condiciones de radiación térmica suficientes en la capa de gases, para que se dé el *flashover*. Teniendo esto en cuenta, las condiciones para determinar cuándo se está produciendo el *flashover* en los experimentos que se han llevado a cabo en esta investigación, están basadas en trabajos anteriores [10, 11, 64] revisados en el punto 2.2.1, e incluyen las siguientes consideraciones:

- La temperatura medida 1 cm por debajo del techo  $\geq 550^\circ\text{C}$
- El flujo de calor a nivel del suelo  $\geq 20\text{ kW/m}^2$

A esto último hay que añadir que la aparición de este fenómeno está íntimamente relacionada con la localización y tamaño de las aberturas de ventilación [41]. En los recintos con una sola abertura de ventilación, la tasa del flujo másico de aire a través de esta puede estar limitado por los gases calientes que abandonan el espacio confinado, pudiendo generar una situación en la que el recinto no esté suficientemente ventilado. Esto último se ha tenido en cuenta en los experimentos, por lo que se han diseñado con la ventilación adecuada para simplificar los casos.

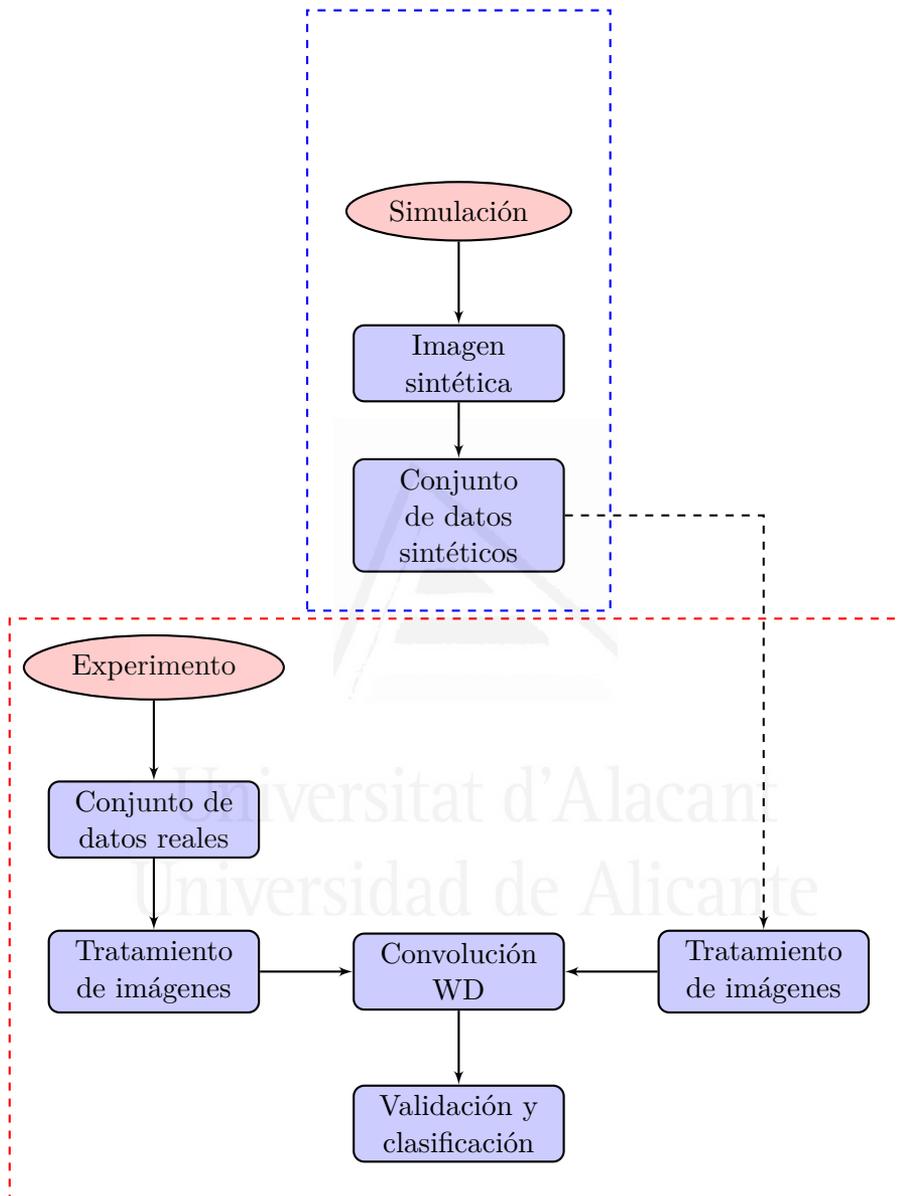
Este capítulo se centra en los métodos propuestos en la sección 1.3 para generar un conjunto de datos sintéticos, a partir del humo que sale a través del hueco de ventilación, así como la validación de estos usando casos reales. Para alcanzar este objetivo, se ha utilizado el software Fire Dynamics Simulator (FDS) para simular dos experimentos a escala reducida. Muchos de los estudios [9, 19, 52, 85, 89] revisados en el apartado 2.3.2 han utilizado esta herramienta en sus investigaciones, y en ellos ha quedado probada su eficacia para realizar simulaciones con un alto grado de precisión. No obstante, no es posible comparar directamente las imágenes sintéticas obtenidas con FDS con las que proporciona la TC. Como se

vio en el apartado [2.4](#), previamente es necesario hacer una serie de transformaciones para obtener imágenes cuantitativas dependientes del tiempo y de la intensidad de radiación del humo que sale a través de la abertura de ventilación. Por este motivo, se han tenido en cuenta en el método propuesto para obtener la imagen sintética, LES, el modelo de radiación de banda estrecha [\[29\]](#), la ecuación de transferencia de radiación térmica y las variables de calibrado de la TC (ver figura [3.1](#), línea discontinua azul).

Una vez se ha definido la obtención de las imágenes sintéticas, aplicando las transformaciones necesarias descritas en el párrafo anterior, se procede a crear el conjunto de datos sintéticos. Para hacer esto se ha utilizado una frecuencia de adquisición, almacenando los datos de intensidad de cada imagen sintética en archivos para su posterior utilización. De esta manera, el conjunto de datos sintéticos de cada simulación está formado por número determinado de archivos, que depende de la duración de la simulación y la frecuencia de adquisición propuesta.

Para poder utilizar el conjunto de datos sintéticos, con el motivo de hacer predicciones utilizando técnicas de inteligencia artificial, es necesario realizar una validación de las imágenes obtenidas. Por este motivo, se ha propuesto un método de validación (ver figura [3.1](#), línea discontinua roja) para el que se han diseñado dos experimentos reales a pequeña escala (ver apartado [3.4](#)) y dos simulaciones de estos casos. En el método propuesto se coloca una TC en el exterior del recinto y las imágenes reales se extraen del vídeo obtenido con la TC para los dos casos diseñados. Las imágenes sintéticas se obtienen de las simulaciones realizadas de los casos propuestos aplicando las transformaciones necesarias. Finalmente, se realiza una comparación cuantitativa de las imágenes transformadas sintéticas con las obtenidas con la TC y se discuten los resultados. Para poder realizar los cálculos y el tratamiento de los datos que los métodos propuestos requieren, se han diseñado diferentes scripts en python 3.7 [\[7\]](#).

En los apartados que se muestran a continuación se explican los pasos y técnicas utilizadas para llevar a cabo el proceso.



**Figura 3.1:** Métodos propuestos en este capítulo. Método para generar el conjunto de datos sintéticos (línea discontinua azul). Método para validar y clasificar el conjunto de datos sintéticos (línea discontinua roja)

## 3.2. Método para generar conjuntos de datos de imágenes sintéticas

El método propuesto en esta tesis para la predicción del *flashover*, se basa en evaluar la situación desde el exterior del recinto. Para hacer esto, se ha considerado una localización de la cámara perpendicular a la pared del hueco de ventilación (ver figura 3.8) por las siguientes razones:

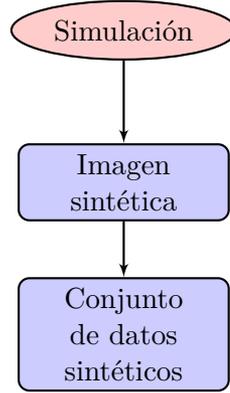
- **Evitar daños personales.** Una localización de la cámara orientada hacia la fachada principal donde se sitúa el hueco de ventilación, puede provocar daños serios al personal de intervención al ser alcanzados por materiales proyectados hacia el exterior.
- **Evitar enfocar al material en combustión.** En ciertas ocasiones es posible que el combustible en llamas pueda ser localizado por el hueco de ventilación. Esto puede llevar a errores en la predicción del fenómeno.

Para generar las imágenes sintéticas a partir de simulaciones, son necesarios una serie de pasos para poder obtener una imagen que se asemeje a la obtenida por una TC determinada. A continuación, se describen todos los pasos seguidos para obtener el conjunto de datos sintéticos con el método propuesto (ver figura 3.2).

### 3.2.1. Simulaciones numéricas

Las simulaciones numéricas de este trabajo se han llevado a cabo utilizando la versión del software FDS 6.5.3 [3]. En la configuración de las simulaciones se ha tenido en cuenta el modelo de turbulencia LES y el modelo de un solo paso o modelo químico simple, el cual considera que la materia combustible está compuesta por  $C$ ,  $H$ ,  $O$  y  $N$  y reaccionan con el  $O_2$  para formar  $H_2O$ ,  $CO_2$ ,  $CO$  y humo, para este caso el combustible empleado es diésel.

El tamaño computacional de la simulación en este caso depende principalmente de las dimensiones del recinto confinado, del humo que sale por el



**Figura 3.2:** Flujograma del método propuesto para generar el conjunto de datos sintéticos.

hueco de ventilación y de la posición de los sensores para obtener los datos necesarios. Teniendo en cuenta lo anterior, los tamaños computacionales que se ajustan a las simulaciones de las experimentaciones realizadas son:  $1.344 \text{ m} \times 2.24 \text{ m} \times 0.768 \text{ m}$  para el experimento 1; y,  $1.344 \text{ m} \times 0.64 \text{ m} \times 0.768 \text{ m}$  para el experimento 2. El tamaño de los volúmenes de control o celdas en una simulación de este tipo es un punto a tener en cuenta para reducir el coste computacional. Para este caso de estudio (*flashover*), la zona de combustión, el hueco de ventilación y el humo en la parte exterior del recinto necesitan especial atención. Según la ecuación 3.1, el diámetro del fuego (en el caso de recipientes con combustibles líquidos circulares) está relacionado con la tasa de liberación de calor  $\dot{Q}$ . MacGrattan et al. [56], sugiere un tamaño óptimo de celda ( $\delta x$ ) 10 % of  $D^*$  (ver ecuación 3.2).

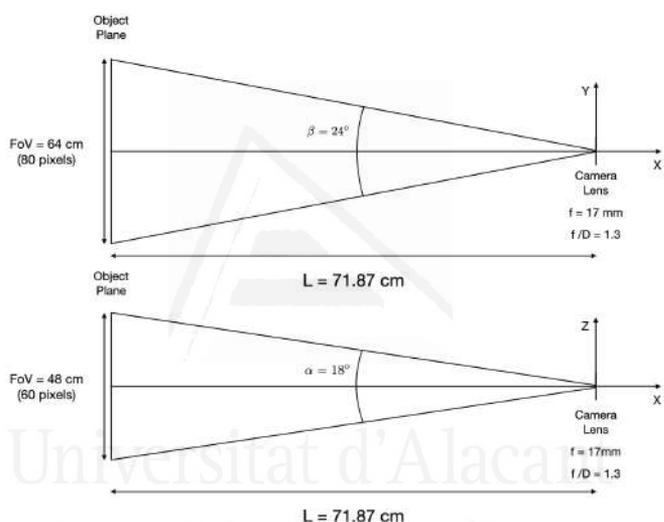
$$D^* = \left[ \frac{\dot{Q}}{\rho_\infty C_\infty T_\infty \sqrt{g}} \right]^{2/5} \quad (3.1)$$

$$\delta_x = 0.1 \cdot D^* \quad (3.2)$$

En la ecuación 3.1,  $\dot{Q}$  es la tasa total de calor liberado (kW),  $\rho_\infty$  es la densidad atmosférica ( $\text{kg}/\text{m}^3$ ),  $C_\infty$  es el calor específico del aire ( $\text{kJ}/\text{kg}\cdot\text{K}$ ),  $T_\infty$  es la temperatura ambiental (K) y  $g$  es la aceleración de la gravedad ( $\text{m}/\text{s}^2$ ). Teniendo en cuenta que  $\dot{Q}_{fuel\,designed(diesel)}$  es 6.55 kW y la tempe-

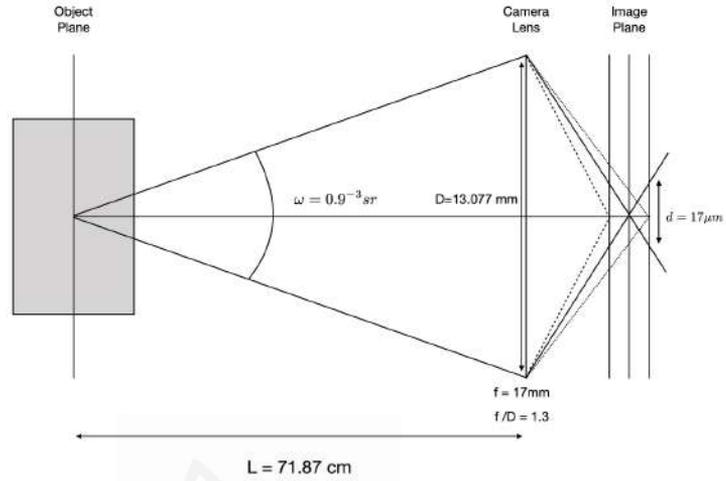
ratura ambiental es de  $32\text{ }^{\circ}\text{C}$ , el tamaño de celda, sustituyendo los valores en las ecuaciones anteriores, tiene que ser  $\leq 1.3\text{ cm}$ . Además de esto, es necesario evaluar otros factores para asegurar la precisión de la simulación en la zona de la abertura de ventilación [89]. En este trabajo, se ha considerado un factor de ventilación  $l_1^*$  teniendo en cuenta que, valores de  $l_1^* \geq 10$  reducen el 'error' del balance de masa por debajo del below 4 %.

$$l_1^* = l_1/\delta_x = (A\sqrt{H})^{2/5}/\delta_x \quad (3.3)$$



**Figura 3.3:** Flir E75, campo de visión (FoV, *Field of View*) en la simulación

En relación con este último parámetro, la celda sugerida para los experimentos es  $\delta_x \leq 2.2\text{ cm}$ . Por lo que, si se elige el valor más restrictivo, el tamaño óptimo para la celda es  $\leq 1.3\text{ cm}$ . Pero el tamaño de la celda no está determinado únicamente por el combustible y el factor de ventilación, hay otras consideraciones a tener en cuenta que no tienen que ver con el proceso de simulación, como son los parámetros técnicos de la cámara y localización de esta. Puesto que los experimentos realizados son a pequeña escala, por razones de dimensionamiento se ha elegido un área de interés de  $64\text{ cm} \times 48\text{ cm}$ , siendo la resolución de la cámara  $320 \times 240$  píxeles, el tamaño de celda sería de  $2\text{ mm}$ . Esta medida para el volumen de control



**Figura 3.4:** Disposición óptica ideal de la TC según el área de interés elegida

genera un coste computacional muy elevado, por esta razón se ha utilizado un tamaño final de celda de 8 mm, lo que genera un área de interés de  $80 \times 60$  píxeles ( $64 \text{ cm} \times 48 \text{ cm}$ ), siendo el tamaño del resto de celdas de 1.6 cm (ver figuras [3.5b](#) y [3.6b](#)). Al utilizar un tamaño de celda 3 mm superior al recomendado en algunas zonas de la simulación (1.3 cm - 1.6 cm) se decide realizar dos simulaciones con ambos tamaños de celda para comparar los resultados y se concluye que no hay cambios significativos en los resultados. Para reducir el coste computacional las simulaciones se dividen en diferentes mallas: en el experimento 1 se utilizan 6 mallas de 1.6 cm y una de 8 mm (ver figura [3.5](#)), siendo el número total de celdas en el dominio computacional  $(41 \times 40 \times 48) + 2 \times (43 \times 15 \times 48) + 2 \times (43 \times 10 \times 6) + (86 \times 20 \times 72) + (43 \times 70 \times 48) = 414\,120$ ; en el caso de experimento 2, el número de mallas configuradas con un tamaño de celda de 1.6 cm fueron 5 y una malla adicional con 8 mm (ver figura [3.6](#)), por lo que el número total de celdas para esta simulación es  $(38 \times 32 \times 40) + 2 \times (40 \times 10 \times 40) + (40 \times 12 \times 4) + (40 \times 12 \times 6) + (80 \times 24 \times 60) = 200\,640$ . En relación con el consumo de combustible en las simulaciones, se han tenido en

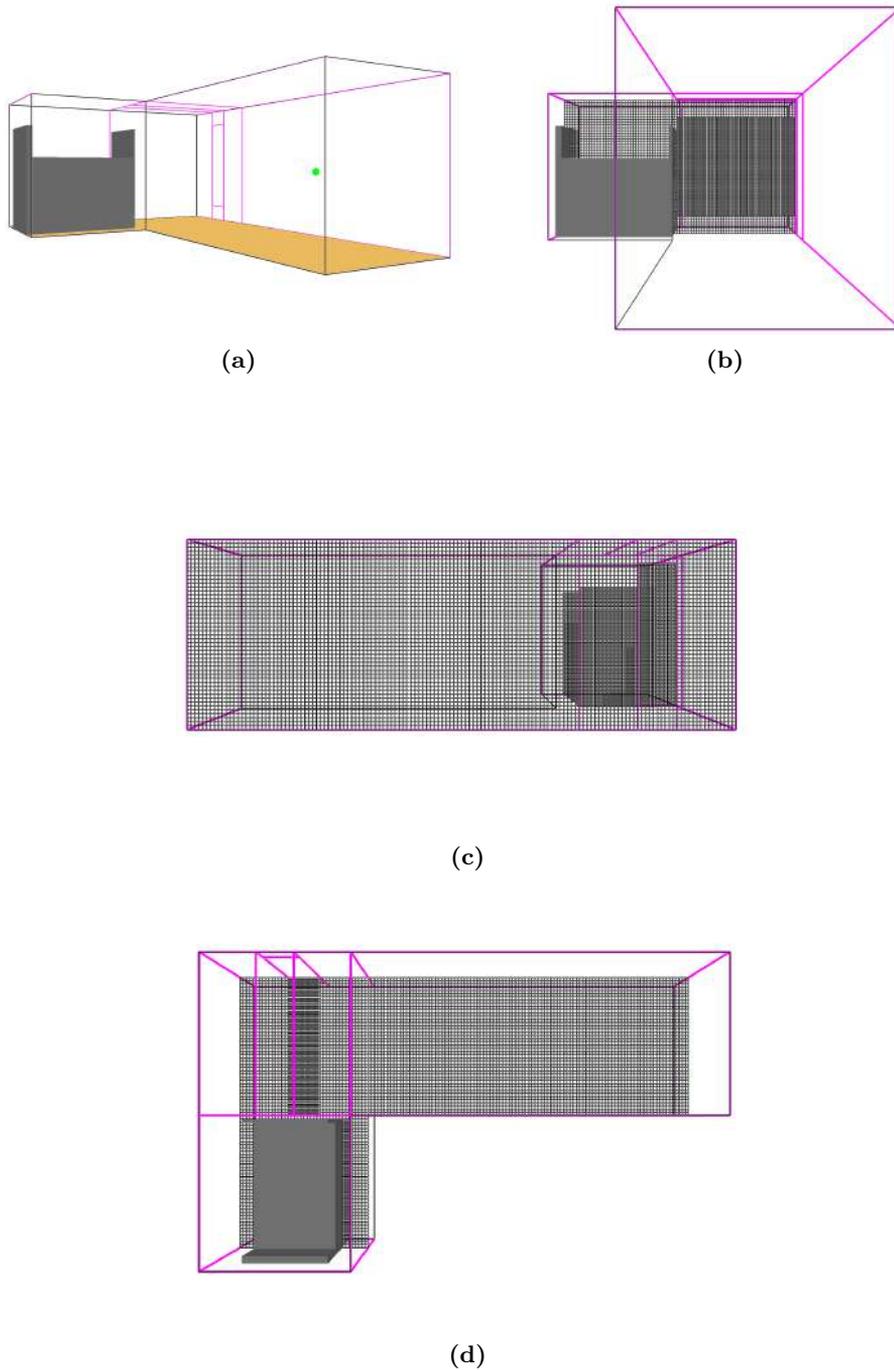
cuenta los datos de consumo de diésel de los experimentos reales obtenidos con la báscula electrónica (ver tablas 3.1 y 3.3). En el caso de los paneles de fibra de madera, los datos introducidos para simular la combustión han sido obtenidos del estudio EUROFIC 4 [74] (ver tabla 3.2).

Combustible: diesel	
Tiempo	Fracción de combustible
T = 0	F = 0.091
T = 50	F = 0.172
T = 120	F = 0.192
T = 470	F = 0.200
T = 600	F = 0.250

**Tabla 3.1:** Consumo de combustible en el experimento 1

Combustible: Tablero de madera (MDF)	
Tiempo	Fracción de combustible
T = 0	F = 0.00
T = 43,75	F = 0.00
T = 50	F = 1.00
T = 125	F = 0.60
T = 200	F = 0.47
T = 325	F = 0.41
T = 400	F = 0.38
T = 500	F = 0.30
T = 600	F = 0.30
T = 700	F = 0.37

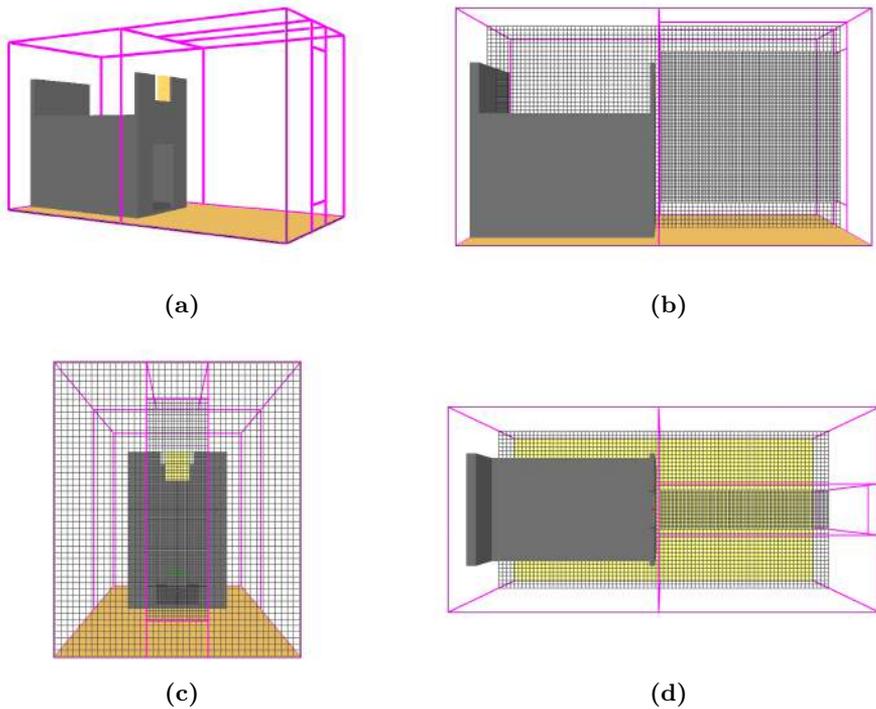
**Tabla 3.2:** Evolución de la combustión del tablero de madera MDF usada en ambos experimentos.



**Figura 3.5:** Configuración de la simulación para experimento 1. Los límites de las diferentes mallas pueden identificarse en color rosa. (a) Configuración de mallas para el experimento 1. El punto verde simboliza el PTHFM (b) Vista en alzado. (c) Vista frontal. (d) Vista en planta.

Combustible: diesel	
Tiempo	Fracción de combustible
T = 0	F = 0.091
T = 50	F = 0.182
T = 300	F = 0.182
T = 470	F = 0.3863

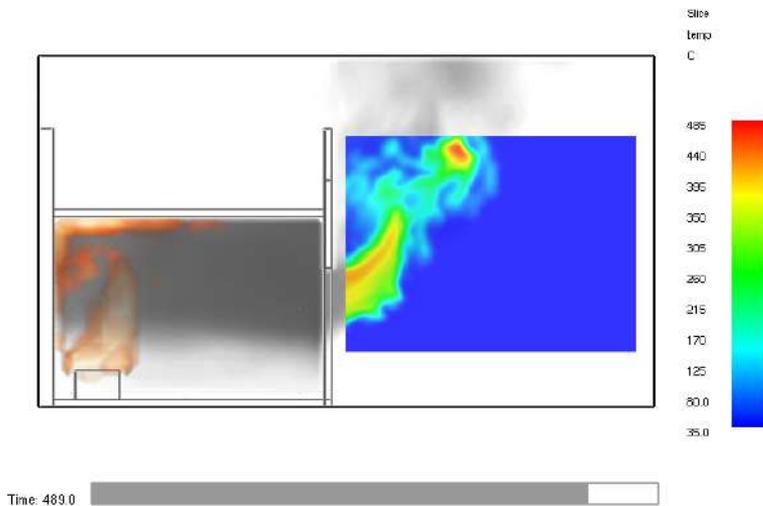
**Tabla 3.3:** Consumo de combustible en el experimento 2



**Figura 3.6:** Configuración de la simulación para experimento 2. Los límites de las diferentes mallas pueden identificarse en color rosa. (a) Configuración de mallas para el experimento 2. Puede identificarse el PTHFM en color amarillo encima del hueco de ventilación. (b) Vista en alzado. (c) Vista frontal. (d) Vista en planta.

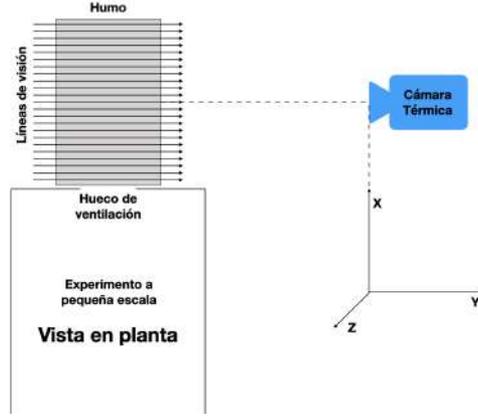
### 3.2.2. Generación de imágenes sintéticas

En esta investigación, las imágenes sintéticas son obtenidas utilizando FDS, el modelo de radiación de banda estrecha y la ecuación de transferencia de radiación térmica. Se ha discretizado el área de estudio que incluye el humo que sale del recinto por el hueco de ventilación, en las simulaciones descritas en el punto [3.2.1](#), utilizando coordenadas rectangulares. Los datos de interés (temperatura, presión, fracción molar de los gases involucrados y productos en suspensión en la capa de gases) se extraen de la simulación usando la herramienta *fds2ascii* proporcionada por el propio software.



**Figura 3.7:** Representación térmica del área de interés en la simulación 2

Los datos obtenidos son almacenados en archivos para su posterior tratamiento. Para calcular la longitud de la trayectoria se tiene en cuenta cada volumen de control diferencial y se utilizaron líneas de visión paralelas para realizar los cálculos del área de estudio (ver figura [3.8](#)). Cada línea de visión está conformada por celdas en el mismo plano, perpendicularmente a la dirección de la TC. Para este caso particular de estudio, donde los gases y humos evaluados se encuentran fuera del recinto, ha sido considerada la radiación incidente del humo que sale por el hueco de ventilación. Por lo tanto, la ecuación de transferencia radiativa utilizada en este experimento es:



**Figura 3.8:** Método propuesto para la generación de imágenes sintéticas para la predicción del *flashover*. Las líneas de visión atraviesan el humo (área de interés) en dirección a la TC.

$$I = \int_{\lambda_1}^{\lambda_2} \alpha_\lambda I_\lambda(0) e^{-(\tau_\lambda)} d\lambda + \int_{\lambda_1}^{\lambda_2} \int_0^{\tau_\lambda} \alpha_\lambda I_{b\lambda}(\tau_\lambda^*) e^{-(\tau_\lambda - \tau_\lambda^*)} d\tau_\lambda^* d\lambda \quad (3.4)$$

Dónde  $I_\lambda(0)$  y  $I_{b\lambda}$  son las intensidades en el punto inicial a lo largo de la trayectoria y la intensidad espectral del cuerpo negro respectivamente,  $\alpha_\lambda$  es el coeficiente espectral de la TC, y  $\lambda_1$  y  $\lambda_2$  son los límites de ancho de banda del filtro. La ecuación 3.5 representa el espesor óptico espectral de los gases que componen la capa de humo, donde  $K_\lambda$  es el coeficiente de absorción espectral y  $S$  es la longitud de la trayectoria.

$$\tau_\lambda = \int_0^S K_\lambda ds \quad (3.5)$$

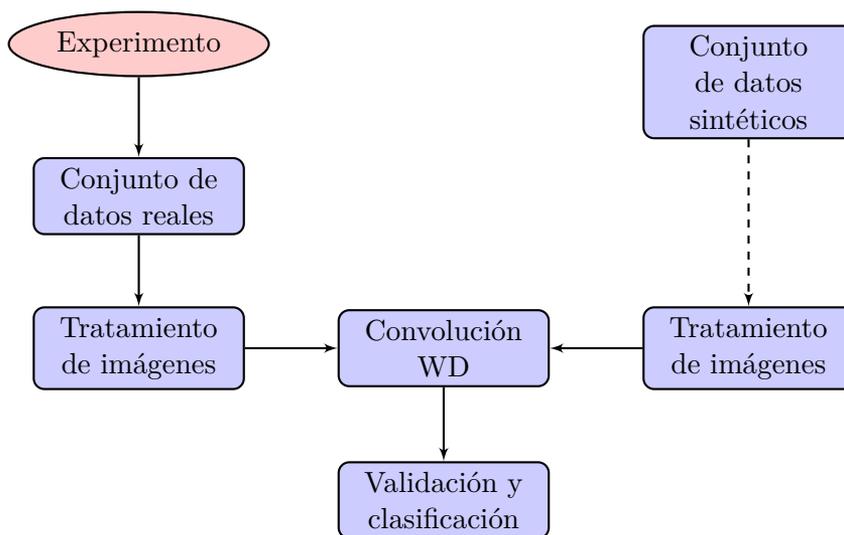
Los valores de temperatura, presión, fracción molar de los gases involucrados y de productos en suspensión en la capa de gases, se utilizan junto con un modelo de radiación de banda estrecha (RADCAL) [30] para calcular el coeficiente de absorción espectral ( $K_\lambda$ ). La radiación térmica se calcula instantáneamente, integrando lo largo de las líneas de visión a través de la capa de humo, utilizando la respuesta espectral de la cámara e integrando sobre el rango espectral del filtro. Los datos de radiación térmica obtenidos se almacenan en archivos para su posterior tratamiento.

### 3.2.3. Generación del conjunto de datos sintéticos

Una vez descrito el proceso para la creación de imágenes sintéticas a partir de una simulación de fluidos computacional, se procede a la creación de los conjuntos de datos sintéticos para poder realizar la validación y clasificación. Para esto se crean dos conjuntos de datos sintéticos para las dos simulaciones diseñadas. La frecuencia de creación de imágenes se fija en 1 segundo, siendo el tiempo de duración 700 segundos para la simulación 1 y 600 segundos para la simulación 2. Por lo tanto, el conjunto de datos para la simulación 1 lo componen 700 archivos y 600 para la simulación 2. Teniendo en cuenta que las imágenes de la simulación tienen una resolución de  $80 \times 60$ , cada archivo está compuesto por 4 800 datos de radiación. Por lo tanto, el conjunto de datos de la simulación 1 se compone de 3 360 000 datos y 2 880 000 en el caso de la simulación 2. El conjunto de datos sintético de cada simulación es almacenado en una carpeta para la validación posterior con su correspondiente ensayo real.

## 3.3. Método de validación y clasificación

Con objeto de realizar una comparación entre imágenes para validar el método de obtención, hay que tener en cuenta varios puntos. El bombero que sujeta la cámara térmica en una situación real no puede tener la precisión enfocando el área de interés como en las condiciones que se recrean durante los experimentos. Aspectos como la distancia del objetivo a la cámara, el área de interés o el ángulo de rotación, cambian durante una situación real. Para solventar este problema en la comparación con las imágenes sintéticas (siempre muestran la misma área de interés), se utiliza la distancia Wasserstein en el método propuesto. A continuación, se realiza una introducción de la distancia Wasserstein para pasar posteriormente a explicar el método propuesto en la sección [3.9](#).



**Figura 3.9:** Método para validar y clasificar el conjunto de datos sintéticos

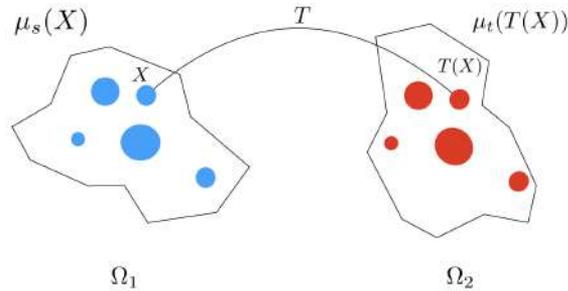
### 3.3.1. Distancia Wasserstein

La  $p^n$  distancia Wasserstein entre dos distribuciones de probabilidad  $\mu$  y  $\nu$  en el espacio de probabilidad  $M$  se define de la siguiente manera:

$$W_p(\mu, \nu) := \left( \inf_{\gamma \in \Gamma(\mu, \nu)} \int_{M \times M} d(x, y)^p d\gamma(x, y)^{1/p} \right) \quad (3.6)$$

Donde  $\Gamma$  es una distribución conjunta sobre  $M \times M$  y debe satisfacer  $\mu$  y  $\nu$  simultáneamente. La métrica  $d$  puede ser cualquier distancia en el espacio de probabilidad en  $M$ . Actualmente la comparación entre dos distribuciones es posible gracias a la teoría del transporte óptimo (OT, *Optimal Transport*) [16] (ver figura 3.10). OT proporciona medios para definir distancias entre distribuciones de probabilidad definidas en espacios métricos potencialmente de alta dimensión. El primer problema de OT fue propuesto en 1781 por el ingeniero francés Gaspard Monge [59]. En el problema original, Monge estaba interesado en encontrar la mejor manera de redistribuir la masa. Más específicamente, en un entorno industrial cómo mover de manera eficiente pilas de mineral desde las minas  $n$  a las fábricas  $m$ . Ese problema permaneció sin resolver desde 1781 hasta los años ochenta

y noventa, cuando los matemáticos finalmente pudieron resolverlo. Hay muchas áreas en las que la teoría de OT se puede aplicar desde entonces, siendo el procesamiento de imágenes el más relevante para este trabajo.



**Figura 3.10:** Representación de la teoría de OT en dos distribuciones de probabilidad

La distancia Wasserstein está motivada por el problema de Monge y se puede comparar con la distancia euclidiana en las distribuciones estadísticas. Esto ofrece la posibilidad de comparar dos distribuciones multidimensionales utilizando una métrica simplificada donde se ha considerado toda la información de las distribuciones originales.

Entre las propiedades más importantes de estas distancias podemos destacar:

- Pueden evaluarse cuando solo se observan medidas empíricas de las distribuciones y no requieren estimar distribuciones paramétricas o semiparamétricas como un preproceso.
- Pueden aprovechar la geometría del espacio métrico subyacente y proporcionar distancias significativas, incluso cuando los apoyos de las distribuciones no se superponen.

### 3.3.2. Tratamiento de las imágenes sintéticas

En la sección [3.2](#) se sentaron las bases para la creación del conjunto de datos sintéticos. Cada archivo de este conjunto de datos tiene unas dimensiones de  $80 \times 60$ , sin embargo, los datos que se obtienen con la cámara térmica tienen unas dimensiones de  $320 \times 240$ . Para poder realizar la convolución utilizando la distancia Wasserstein es necesario que los datos (reales y sintéticos) tengan las mismas dimensiones. Por esta razón, previamente a este paso es necesario realizar un redimensionamiento de los datos. En este trabajo se ha considerado realizar este punto sobre los datos sintéticos con el fin de no alterar los datos reales, pasando estos de  $80 \times 60$  a  $320 \times 240$ .

### 3.3.3. Convolución WD

Para poder validar los datos sintéticos obtenidos se decide realizar una convolución usando la distancia Wasserstein. Para esto se compara cada archivo del conjunto de datos reales con cada archivo del conjunto de datos sintético para obtener la distancia Wasserstein. Es decir, el primer archivo de datos reales se compara con la totalidad de los archivos de datos sintéticos, de manera que la menor distancia Wasserstein obtenida indica una mayor similitud entre los dos archivos. Este proceso se repite con cada archivo del conjunto de datos reales. De esta manera es posible establecer una relación temporal entre los datos sintéticos y los reales.

### 3.3.4. Validación y clasificación

La validación y clasificación de los datos obtenidos se realiza utilizando los datos que se obtienen de la convolución realizada en el apartado anterior. Para esto se representan los datos reales frente a los datos sintéticos utilizando dos escalas temporales que representan la duración del experimento y de la simulación respectivamente (ver figuras [3.20](#), [3.21](#), [3.24](#) y [3.25](#)). Se utilizan los datos de los sensores del experimento (ver figuras [3.18](#) y [3.19](#)) y de la simulación (ver figuras [3.22](#) y [3.23](#)) para dividir el gráfico en los diferentes estadios utilizando líneas verticales para el experimento y líneas horizontales para la simulación. De esta manera cada estadio queda

delimitado por líneas establecidas siendo fácilmente identificable si los datos simulados o experimentales son clasificados dentro del mismo estadio.

## 3.4. Método experimental

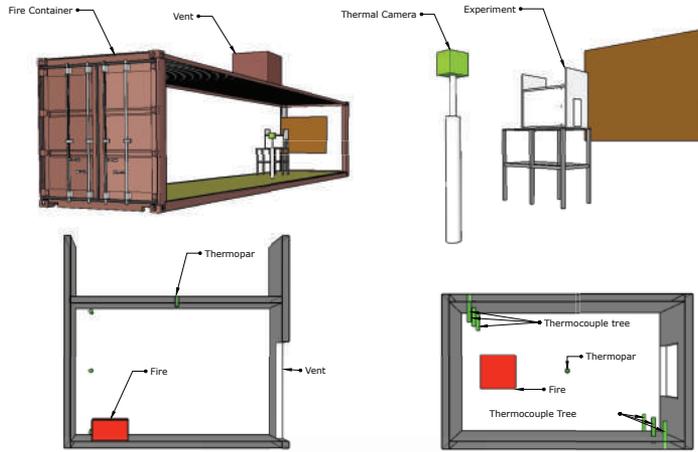
En este apartado se muestran en detalle los experimentos que se han llevado a cabo para poder realizar la validación de los conjuntos de datos sintéticos.

### 3.4.1. Detalles experimentales

Para poder validar los datos sintéticos transformados obtenidos a partir de simulaciones, se han diseñado dos experimentos a pequeña escala con el objetivo de realizar una comparación. Los experimentos (ver figura [3.11](#)) se llevaron a cabo en el interior de un contenedor de fuego, perteneciente al Consorcio Provincial de Bomberos de Alicante y localizado en las instalaciones del parque de bomberos de San Vicente del Raspeig.

Un contenedor de fuego es básicamente un contenedor de los que se usa en transportes marítimos, al que se le han hecho algunas modificaciones para que los servicios de emergencias puedan realizar prácticas de fuego en el interior. Este tipo de contenedores están fabricados con un tipo de acero resistente a las condiciones que se pueden dar en entornos marítimos, especificado en la norma UNE-EN 10025-5:2007 (hot rolled products of structural steels - Part 5: Technical delivery conditions for structural steels with improved atmospheric corrosion resistance).

La función principal del contenedor de fuego durante la fase de experimentación es proporcionar unas condiciones ambientales adecuadas, evitando así las acciones externas del viento. Las dimensiones del recinto para los experimentos diseñados son  $0.60\text{ m} \times 0.357\text{ m} \times 0.395\text{ m}$ , contando con una única abertura de ventilación de  $0.285\text{ m} \times 0.15\text{ m}$ . Los materiales utilizados para la construcción del recinto, en ambos casos, consisten en paneles de fibra de madera de media densidad con las siguientes características: espesor  $0.019\text{ m}$ , densidad  $758\text{ kg/m}^3$ , conductividad térmica



**Figura 3.11:** Método experimental propuesto. La imagen superior-izquierda muestra la localización de los experimentos en el interior del contenedor de fuego. Arriba a la derecha se muestra la localización de la cámara en el experimento. Las imágenes en el plano inferior muestran un sketch del recinto confinado y la localización de los dispositivos de medida utilizados.

0.2 W/m·K, emisividad 0.9, y poder calorífico 1700 J/kg·K. Para poder alcanzar las condiciones de *flashover*, es importante calcular la cantidad de combustible necesario. De acuerdo con el criterio de Thomas [71], el *flashover* únicamente ocurre cuando se alcanzan ciertos valores críticos relacionados con las dimensiones del hueco de ventilación. En el caso de recintos confinados con una única abertura, la ecuación de Thomas a utilizar es la siguiente:

$$\dot{Q}_f = 378A_v\sqrt{H_v} + 7.8A_T \quad (3.7)$$

Donde  $A_v$  es el área calculada del hueco de ventilación,  $H_v$  es la altura del hueco de ventilación, y  $A_T$  es el área disponible del recinto en la que puede darse una transferencia de calor.

$$A_v = H_v B_v \quad (3.8)$$

Para los experimentos de este estudio  $A_v = 0.04275 \text{ m}^2$ ,  $H_v = 0.285 \text{ m}$

y  $B_v = 0.15$  m. Las medidas interiores del recinto confinado en ambos casos son 60 cm de largo, 35.7 cm de ancho, y 39.5 cm de alto.

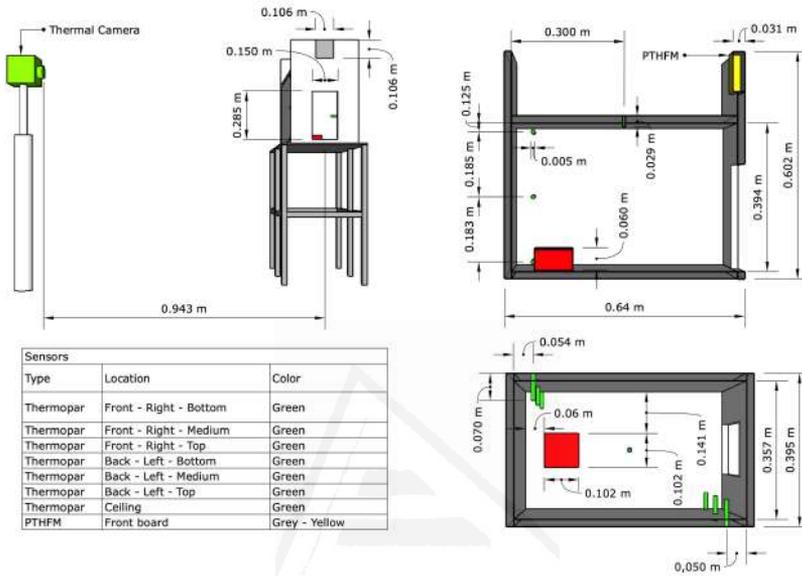


Figura 3.12: Sketch del experimento 2.

El área disponible del recinto en la que puede darse transferencias de calor se calcula como se muestra a continuación:

$$A_T = 2 \cdot 0.6 \text{ m} \cdot 0.395 \text{ m} + 2 \cdot 0.357 \text{ m} \cdot 0.395 \text{ m} + 2 \cdot 0.6 \text{ m} \cdot 0.357 \text{ m} - 0.285 \text{ m} \cdot 0.15 \text{ m} = 1.1417 \text{ m}^2 \quad (3.9)$$

Por lo tanto  $\dot{Q}_{fuel}$ :

$$\dot{Q}_{fuel} = 378 \cdot 0.04275 \cdot \sqrt{0.285} + 7.8 \cdot 1.1417 = 17.532 \text{ kW} \quad (3.10)$$

De acuerdo con la ecuación de Thomas, para alcanzar el *flashover* en los experimentos propuestos es necesaria una potencia calorífica mínima de 17.532 kW, teniendo en cuenta que el poder calorífico superior (PCS) del diésel es 42 MJ:

$$\dot{Q}_{fueldesigned(diesel)} = 42\,000 \frac{\text{kJ}}{\text{kg}} \cdot 0.015 \frac{\text{kg}}{\text{m}^2 \cdot \text{s}} \cdot (0.102 \text{ m})^2 = 6.55 \text{ kW} \quad (3.11)$$

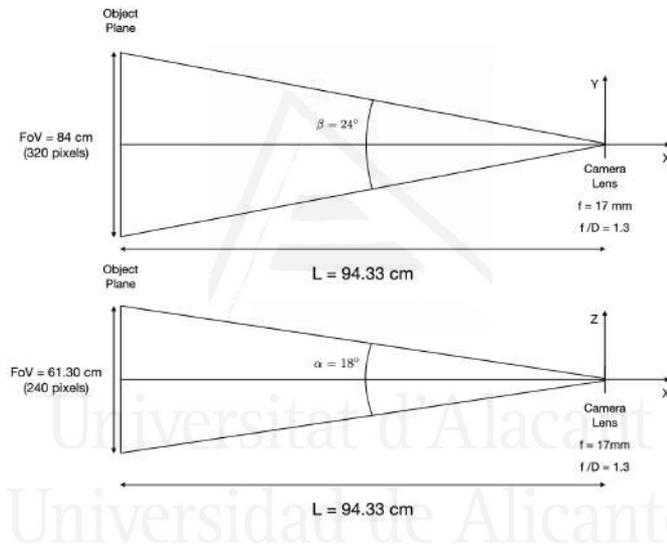
$$\dot{Q}_{fueldesigned(fibreboard)} = 130 \frac{\text{kW}}{\text{m}^2} \cdot (0.3 \text{ m})^2 = 11.7 \text{ kW} \quad (3.12)$$

$$\begin{aligned} \dot{Q}_{fueldesigned(total)} &= \dot{Q}_{fueldesigned(diesel)} + \dot{Q}_{fueldesigned(fibreboard)} = \\ &= 6.55 \text{ kW} + 11.7 \text{ kW} = 18.25 \text{ kW} \end{aligned} \quad (3.13)$$

Por lo tanto, como  $\dot{Q}_{fueldesigned(total)} > \dot{Q}_{fuel}$ , podemos decir que la condición para que se dé el *flashover* se cumple. En los cálculos se ha tenido en cuenta una contribución mínima del tablero de fibra de madera de 0.3 m<sup>2</sup>. En este punto se han utilizado los datos proporcionados por los test de laboratorio en el estudio Eurific – Cone Calorimeter Test Results [74]. Teniendo en cuenta lo anterior, se considera una tasa mínima de liberación calor de 130 kW/m<sup>2</sup> para el tablero de fibra madera.

El combustible, en este caso diésel, se sitúa en la parte posterior del recinto, cerca de la pared trasera, en un recipiente de acero inoxidable de medidas 10.2 cm × 10.2 cm × 7.5 cm (ver figura 3.12). Para el experimento 1, la distancia desde la pared trasera al recipiente que contiene el combustible es de 6 cm y 5.5 cm para el experimento 2. Con relación a la distancia del recipiente respecto de la línea central que divide el recinto longitudinalmente, en el experimento 1 el recipiente se desplazó 1cm hacia el lado opuesto a los termopares de la parte posterior, mientras que en el experimento 2 el este permanece en el centro.

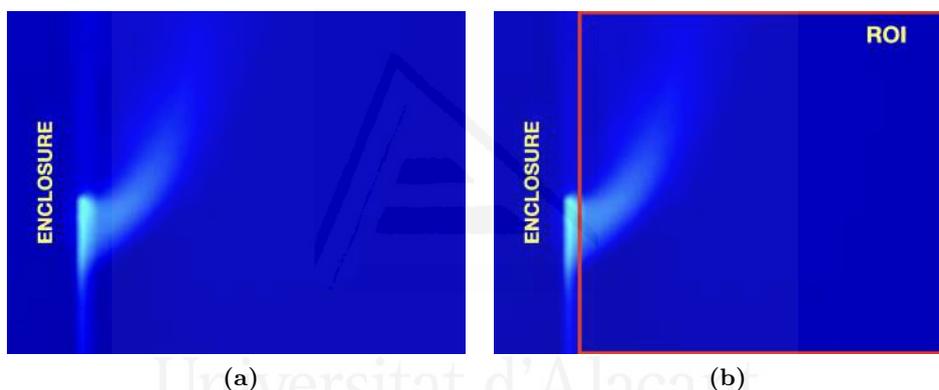
Para medir la radiación térmica en la parte exterior del recinto, debemos tener en cuenta algunas consideraciones. Las imágenes térmicas son obtenidas con una cámara FlirE75, siendo el rango de temperaturas que es capaz de abarcar,  $0-650^{\circ}\text{C}$ , similar a las cámaras que son utilizadas por los servicios de bomberos. La posición de la cámara es calculada teniendo en cuenta el campo de visión ( $320 \times 240$  píxeles, Figura 3.13), la distancia focal y la apertura relativa son 17 mm y 1.3 respectivamente (ver figura 3.13).



**Figura 3.13:** Flir E75, campo de visión (FoV, *Field of View*) en el experimento

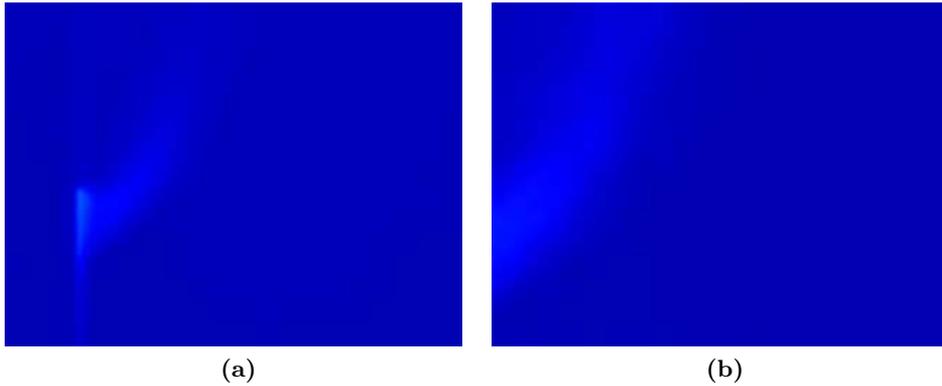
La cámara se monta perpendicularmente a la pared principal del recinto, donde está situada la abertura de ventilación (94.33 cm desde el punto central de la abertura de ventilación). Esta distancia es mayor que la que se corresponde con el área de interés utilizada para llevar a cabo las simulaciones (ver 3.3). La razón de esto se fundamenta en la dificultad de obtener imágenes térmicas del área de interés en una situación real, ya que el bombero que está sujetando la cámara, no puede mantener permanentemente la misma área de interés durante la intervención. Por este motivo en los experimentos se ha aumentado la distancia de la cámara con respecto a

la distancia ideal (71.87 cm), con el objetivo de obtener un área de interés mayor (ver figura 3.15). En las imágenes de obtenidas con la TC se incluye también parte del recinto confinado con el motivo de poder utilizar dos entradas diferentes de la imagen real, utilizando la imagen original (IMAGE) o el área de interés (ROI, *Region Of Interest*) obtenida a partir de esta (ver figuras 3.11 y 3.12). De esta manera es posible conocer cómo varía la efectividad de la validación y clasificación según la entrada empleada, y en caso de encontrar diferencias significativas, sería necesario aplicar ciertas transformaciones a la imagen original.



**Figura 3.14:** Imágenes de la TC. (a) Representa la imagen original, usada en la primera comparación. (b) El cuadrado rojo representa el área de interés (ROI) de la imagen original para hacer la segunda comparación.

Se han desarrollado varios scripts usando python 3.7.7 [7] con el objetivo de analizar y tratar los datos de las simulaciones y de la TC. Por otro lado, para llevar a cabo la comparación de las imágenes con la distancia Wasserstein, estas deben tener las mismas dimensiones [6]. La imagen de la TC tiene unas dimensiones de  $320 \times 240$  píxeles, si bien, en la comparación usando la entrada ROI, el área de interés es extraída de esta por lo que es necesario convertir la parte obtenida en una imagen de  $320 \times 240$ . Para hacer esto se emplearon funciones de OpenCV [5], al igual que para redimensionar la imagen sintética de  $80 \times 60$  a  $320 \times 240$ .



**Figura 3.15:** (a) Imagen de la TC incluyendo parte del recinto a una distancia de 94.33 cm. (b) Imagen sintética del área de interés (ROI) correspondiente a una distancia de 71.87 cm.

La frecuencia de adquisición de imágenes de la cámara es 30 Hz, por lo que teniendo en cuenta que el tiempo total para el experimento 1 es de 700 segundos y para el experimento 2 es 600 segundos, se generaron 21 000 y 18 000 imágenes respectivamente. Se utilizaron tableros de corcho situados a 1.5 metros del plano central del área de interés, para evitar la radiación proveniente de las paredes del contenedor de fuego.

### 3.4.2. Dispositivos de medida

Con motivo de obtener los datos necesarios para evaluar los experimentos, se utilizaron diferentes tipos de sensores. Para conocer la evolución de temperaturas en el interior del recinto, se utilizaron termopares situados en diferentes puntos. Se instaló un termómetro de placa medidor de flujo de calor (PTHFM, *Plate Thermometer Heat Flux Meter*) en la parte exterior del compartimento para comprobar la radiación térmica proveniente del humo y comparar los valores con los resultados de las simulaciones. Las imágenes se obtuvieron con una TC y para medir el consumo de combustible se utilizó una báscula. A continuación, se explican más en profundidad los sensores utilizados en los dos experimentos.

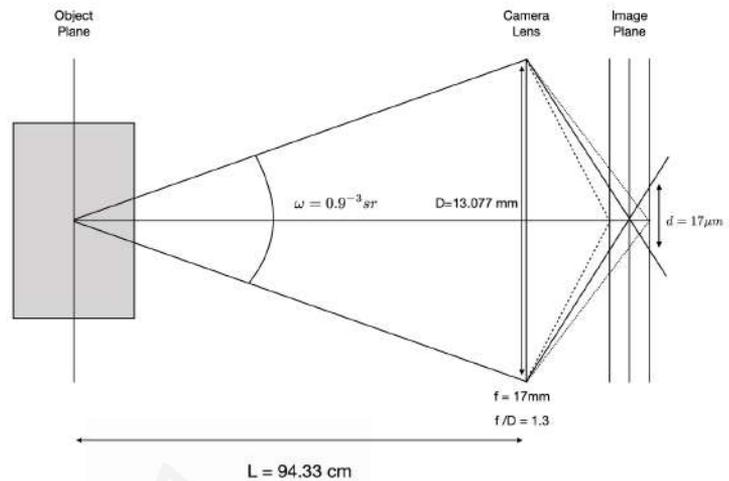


Figura 3.16: Disposición óptica de la TC en el experimento

## Termopares

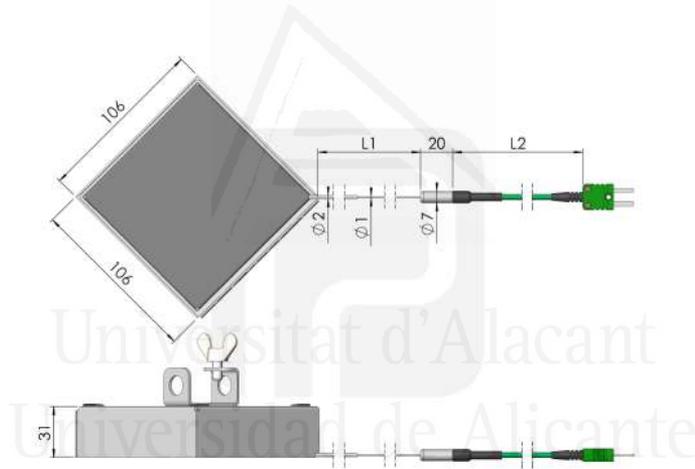
Para medir la temperatura de los gases en el interior del recinto confinado, 7 termopares se distribuyeron de la siguiente manera:

- 1 termopar situado en el centro del compartimento, 1 cm por debajo del techo.
- 3 termopares se situaron a lo largo de la esquina anterior izquierda a diferentes alturas.
- 3 termopares se situaron a lo largo de la esquina posterior derecha a diferentes alturas.

El termopar situado en el centro del compartimento se utiliza para comprobar cuando se alcanza una temperatura  $\geq 550^{\circ}\text{C}$ , primera condición de *flashover*. Para una información más detallada de la posición de los termopares puede referirse a la figura [3.12](#).

### Plate Thermometer Heat Flux Meter (PTHFM)

Este dispositivo (ver figura 3.17) se utiliza para medir la radiación del humo que sale por la abertura de ventilación y su localización varía en función del experimento. En el experimento 1 se sitúa en el punto dónde se encuentra la TC (ver figura 3.5a), no obstante, en el experimento 2 se localiza encima de la abertura de ventilación (ver figura 3.6a). Esto se hace para comparar los valores del flujo de radiación en diferentes posiciones con los valores del mismo dispositivo situado en las simulaciones. Se coloca un PTHFM más en las simulaciones, en el centro del suelo, para verificar la segunda condición de *flashover* y con la intención de encontrar una relación entre el PTHFM fuera y dentro del recinto.



**Figura 3.17:** Plate Thermometer Heat Flux Meter [80]

Según su creador [80], el sensor PTHFM fue desarrollado para reducir las pérdidas de calor por conducción,  $k$ , y la capacidad calorífica,  $C$ , del Plate Thermometer estándar de acuerdo con la ISO 834 y EN 1363-1 (ver las especificaciones técnicas en la tabla 3.4). Es particularmente adecuado para mediciones a temperatura ambiente, como una alternativa práctica a los medidores de flujo de calor refrigerados por agua, para medir el flujo de calor radiante incidente  $\dot{q}_{inc}$  y la temperatura de la superficie adiabática  $T_{AST}$ .

**Tabla 3.4:** PTHFM, especificaciones técnicas

Características	Valor
Máxima temperatura	850 °C (intervalos cortos 1 100 °C)
Placa expuesta de acero inoxidable	0.4 mm
Espesor de la almohadilla de aislamiento	30 mm

### Cámara de imagen térmica

Con motivo de crear un conjunto de datos de imágenes térmicas reales, se utilizó una cámara modelo FlirE75. La principal razón de escoger este tipo de cámara es su similitud a las usadas por los servicios de extinción de incendios, ya que el rango espectral va de 7.5–14  $\mu\text{m}$  y el rango de temperaturas está entre 0 °C y 650 °C. En la tabla que se muestra a continuación (ver tabla 3.5), se listan las principales características técnicas de este dispositivo que se han tenido en cuenta para realizar este trabajo.

**Tabla 3.5:** FlirE75, especificaciones técnicas

Características	Valor
Resolución	320 × 240 píxeles
Campo de visión (FOV)	24° × 18°
Distancia focal	17 mm (0.67 in.)
Resolución espacial (IFOV)	0.90 mrad/píxel
Número f	1.3
Frecuencia	30 Hz
Rango espectral	7.5–14 $\mu\text{m}$
Paso del detector (pitch)	17 $\mu\text{m}$
Rango de temperaturas	0-650 °C (32-1 200 °F)

### Báscula electrónica

Con el objetivo de medir la cantidad de combustible consumido por unidad de tiempo, se utilizó una báscula electrónica. Esta se sitúa debajo del recipiente que contiene el combustible interponiendo entre ambos un tablero de fibra de madera para proteger el dispositivo.

### 3.5. Resultados y discusión

En este estudio se han llevado a cabo dos experimentos para realizar el proceso de comparación y validación de las imágenes. En primer lugar, se discuten los resultados del experimento 1 y su respectiva simulación, a continuación, se utiliza la distancia Wasserstein para realizar la comparación entre ambas. En segundo lugar, se analizan los resultados del experimento 2 y su simulación, utilizando el mismo método que en el caso anterior para realizar la comparación.

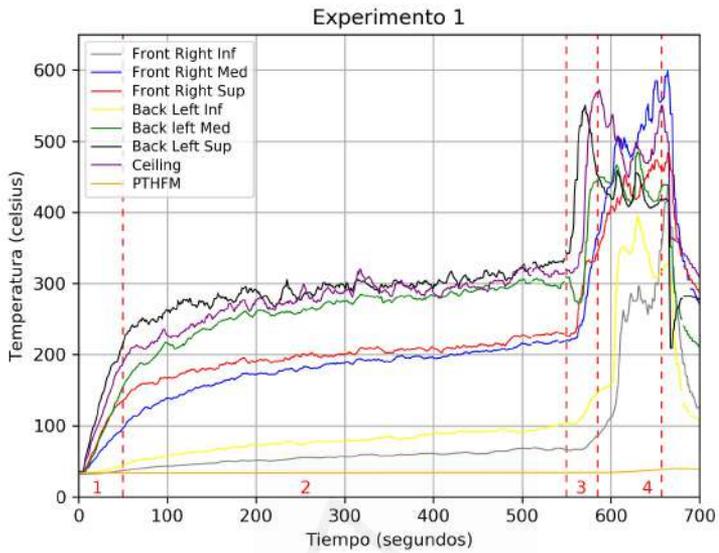
Para una mayor comprensión de los datos expuestos, se ha dividido la representación de la curva estándar de fuego en cuatro etapas (ver figuras 1.3a y 3.18), representadas por un número en la parte inferior del gráfico. La línea discontinua vertical (roja para el experimento real y azul para la simulación) marca el comienzo y el final de cada etapa. En la etapa 1, el comienzo es el origen. El número 1 representa la ignición y el 2 es la etapa de crecimiento. El comienzo de la etapa 3 representa un punto de inflexión, donde el proceso de combustión está cambiando. La línea discontinua que marca el final de la etapa 3 es cuando se alcanza el valor de  $550^{\circ}\text{C}$  1 cm por debajo del techo (primera condición para que se produzca el fenómeno de *flashover*). En el gráfico de datos de simulación hay una línea vertical de puntos que no está en el gráfico de datos reales. El punto donde esta línea cruza la línea de *flashover* (color rosa en el gráfico) muestra cuando la radiación a nivel del suelo alcanza los  $20\text{ kW/m}^2$  (segunda condición para que se produzca el fenómeno *flashover*). Estas líneas discontinuas también se representan en los gráficos de convolución de la distancia Wasserstein para facilitar su explicación. Para evitar confusiones se utilizan líneas discontinuas de color rojo para identificar los estados en los datos reales y azul para las simulaciones. De esta manera es posible identificar cada estado, en el gráfico de datos reales y sintéticos, con el correspondiente número que se sitúa entre dos líneas discontinuas verticales. Debido a que se han realizado dos comparaciones diferentes para cada experimento utilizando la imagen original o el área de interés, se han utilizado dos gráficos diferentes para presentar los resultados de la convolución usando WD. En el primer

gráfico, se representa la convolución WD entre las imágenes obtenidas con la TC que se han modificado para obtener el área de interés (ROI), y las imágenes sintéticas. Por otro lado, en el segundo gráfico se representa la convolución WD entre las imágenes de la TC (sin modificaciones) y las sintéticas.

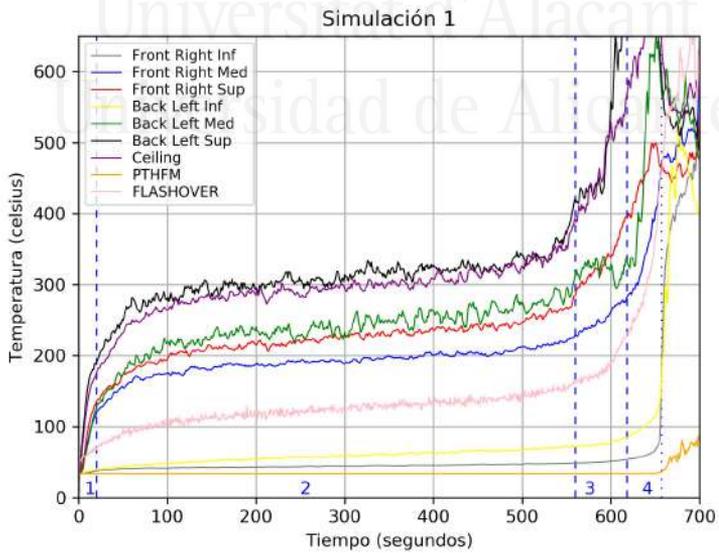
### 3.5.1. Experimento y simulación 1

Los datos del experimento 1 y la simulación correspondiente muestran un alto grado de similitud, pero se pueden identificar algunas diferencias en los gráficos. Teniendo en cuenta que, si las imágenes comparadas fueran iguales para cada instante de tiempo el gráfico convolucional de la WD resultante sería una línea diagonal, podemos identificar el grado de similitud para cada etapa (idealmente una línea de 45 grados), así como qué parte de cada etapa se aproxima más a una diagonal. Además, es posible identificar a simple vista, como es la tasa de liberación de calor (mayor o menor) de uno de los datos comparados en relación al otro, ya que esto depende de si los datos están por encima o por debajo de la diagonal.

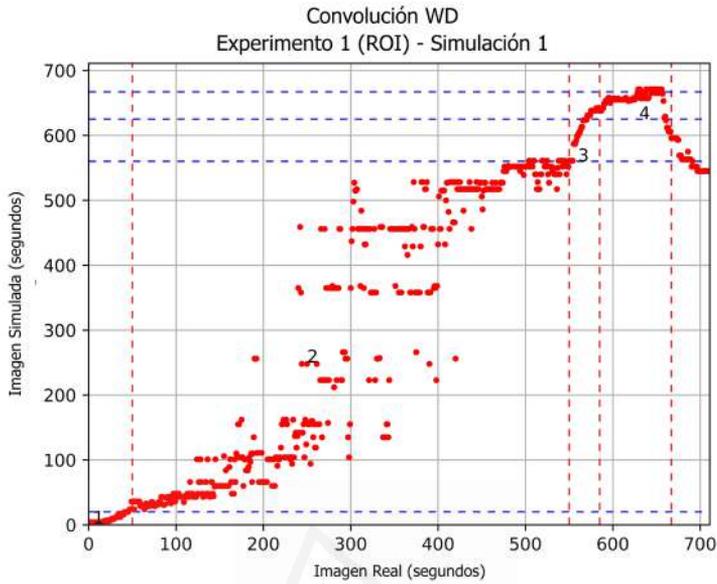
La etapa 1 presenta diferencias entre los datos experimentales y de simulación. Para este caso de estudio, se ha considerado como el final de esta etapa cuando las curvas en los sensores comienzan a estabilizarse. Esto último se ha representado por una línea discontinua a los 50 segundos para datos experimentales (ver figura [3.18](#) etapa 1) y a los 20 segundos en los datos sintéticos (ver figura [3.19](#) etapa 1). Se puede identificar que los datos de los sensores de la simulación tienen líneas con una mayor pendiente en esta etapa. Esto se representa los gráficos [3.20](#) y [3.21](#) como una línea con una pendiente por debajo de 45 grados (pendiente ideal para la comparación del intervalo que va desde 0-0 a 50-50) en la etapa 1, lo que indica que la tasa de liberación de calor en el experimento es menor que en la simulación. La etapa 2 puede parecer similar a simple vista, pero se observan algunas diferencias. Las líneas azul y violeta representan los sensores ubicados en el centro del recinto 1 cm debajo del techo y a media altura en una esquina cercana al hueco de ventilación.



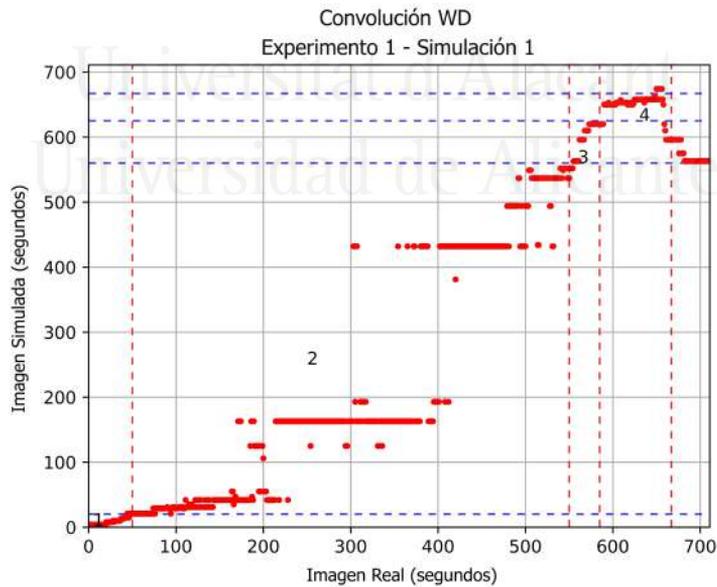
**Figura 3.18:** Datos de los sensores del experimento 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas rojas.



**Figura 3.19:** Datos de sensores en simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas azules.



**Figura 3.20:** Convolución WD entre las imágenes de la cámara térmica (ROI) en el experimento 1 y las imágenes de la simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas.



**Figura 3.21:** Convolución WD entre las imágenes de la cámara térmica (IMAGE) en el experimento 1 y las imágenes de la simulación 1. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas.

Estos sensores revelan diferencias en el intervalo que va desde el final de la etapa 1 hasta unos 300 segundos aproximadamente, aquí los valores de temperatura para el experimento son más bajos que los valores para la simulación. Como en la etapa 1, la tasa de liberación de calor es menor para el experimento y está representada en ambos gráficos para la convolución WD con una pendiente por debajo de la diagonal. A partir de este punto, los valores para los sensores mencionados anteriormente fueron muy similares (pendiente cero). Como consecuencia, las imágenes de la TC y las imágenes de la simulación también son muy similares durante este período de tiempo y la WD tiene dificultades para identificar la imagen correspondiente durante este intervalo. Los datos y las formas son muy similares desde este punto hasta el final de la etapa y esto se representa como un conjunto de datos disperso en los gráficos WD. Aunque en ambos casos la clasificación utilizando la WD ha colocado todos los elementos dentro de la etapa 2, la entrada ROI presenta un nivel de precisión superior. El comienzo de la etapa 3 representa un cambio en la tasa de liberación de calor en el experimento y en la simulación. En este caso la pendiente, en los gráficos de comparación con la WD, es superior a 45 grados en la etapa 3, esto indica que la tasa de liberación de calor es mayor en el experimento. Es posible identificar también esto en los gráficos de los sensores del experimento y de la simulación (ver figuras [3.18](#) y [3.19](#)). En el caso de los datos experimentales las líneas de los sensores en la etapa 3 presentan una evolución casi vertical, mientras que en el caso de la simulación esta evolución presenta una pendiente menor. La convolución WD para las imágenes obtenidas, utilizando la entrada ROI o IMAGE, las clasifica en la etapa correcta para ambos casos. No sólo se han obtenido mejoras en la precisión si comparamos los resultados de la etapa 3 con la 2, sino que también los resultados de las imágenes obtenidas a partir de la entrada ROI presentan una mayor definición. Como se comentó, el final de la etapa 3 representa la primera condición para el *flashover* (temperatura 1 cm debajo del techo  $\geq 550^{\circ}\text{C}$ ). Finalmente, en la etapa 4 a partir de los datos de los sensores, podemos verificar que la temperatura en el nivel superior del recinto se mantiene entre  $500\text{-}600^{\circ}\text{C}$ . Sin embargo, los sensores revelan que la temperatura está aumentando a nivel suelo y a media altura. De

hecho, los cambios de pendiente que muestra el sensor PTHFM en la experimentación coinciden con la línea del sensor de *flashover* (color rosa, ver figura 3.19) cuando alcanza  $454^{\circ}\text{C}$  ( $20\text{kW}/\text{m}^2$ ) a nivel del suelo (segunda condición para el fenómeno de *flashover*). Como resultado se observa que la convolución WD está clasificando las imágenes correctamente en esta etapa (ver figura 3.20 y 3.21, etapa 4). Esto es debido al aumento de temperatura dentro del recinto a nivel medio y por tanto, la temperatura del humo fuera del recinto también aumenta.

Se calcula, para los dos entradas de la imagen real (ROI/IMAGE) propuestas, la matriz de confusión, la sensibilidad o tasa de verdaderos positivos (TPR, *True Positive Rate*), la especificidad o tasa de verdaderos negativos (TNR, *True Negative Rate*), la precisión o valor predictivo positivo (PPV, *Positive Predictive Value*), el valor predictivo negativo (NPV, *Negative Predictive Value*) y los valores de precisión (ACC, *Accuracy Values*) (ver tablas 3.6, 3.7, 3.8 and 3.9). Teniendo en cuenta los valores calculados anteriormente, las etapas 1 y 2 presentan una precisión alta, si bien, la etapa 3 para el experimento y simulación 1, presenta valores más bajos de sensibilidad y PPV cuando se usa la entrada ROI. Esto se debe al número de falsos negativos (FNV, *False Negative Value*) clasificados como S4 (etapa 4, ver 3.6). Este hecho puede ser debido a los criterios de selección del final del estado 3. Analizando los datos del sensor que se encuentra más cerca de la puerta de salida del humo (línea azul), puede observarse que al final se estado 3, en el experimento 1, este alcanza un valor próximo a los  $400^{\circ}\text{C}$ . Para alcanzar el mismo valor en la simulación 1 habría que desplazar la línea del final del estado 3 hacia la derecha transformando los falsos negativos en verdaderos positivos (TPV, *True Positive Values*) con lo que el TPR y el PPV pasarían a ser del 100%. A esto hay que añadir que, la etapa 3 representa un cambio rápido de combustión mayor en el experimento 1 que en la simulación 1 y las imágenes podrían verse afectadas por el tiempo de demora entre las condiciones físicas internas y externas. Además de esto hay que tener en cuenta que, el tiempo empleado en esta comparación entre imágenes fue de 1 segundo, por lo que reduciendo este tiempo es posible que se obtengan mejores resultados. A pesar de los valo-

res más bajos para esta etapa (etapa 3, ver tablas 3.7 y 3.9) y teniendo en cuenta los valores para las etapas 2 y 4 y la precisión para todas las etapas, es posible afirmar que la etapa 3 se puede identificar correctamente con ambas entradas (ROI/IMAGE). Los resultados obtenidos con la entrada IMAGE sugieren que puede utilizarse para realizar la clasificación de las imágenes en sus diferentes estados.

**Tabla 3.6:** Matriz de confusión para el experimento 1 (ROI) y la simulación 1. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.

	R1	R2	R3	R4
S1	46	0	0	0
S2	5	486	0	0
S3	0	14	20	6
S4	0	0	15	59

**Tabla 3.7:** Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 1 (ROI) y simulación 1.

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
Etapa 1	90.20	100	100	100	99.23
Etapa 2	97.20	96.67	98.98	96.15	97.08
Etapa 3	57.14	96.75	50.00	97.69	94.64
Etapa 4	90.77	97.40	79.73	97.35	96.77

**Tabla 3.8:** Matriz de confusión para el experimento 1 (IMAGE) y la simulación 1. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.

	R1	R2	R3	R4
S1	46	0	0	0
S2	5	500	4	0
S3	0	6	31	12
S4	0	0	0	64

**Tabla 3.9:** Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 1 (IMAGE) y simulación 1.

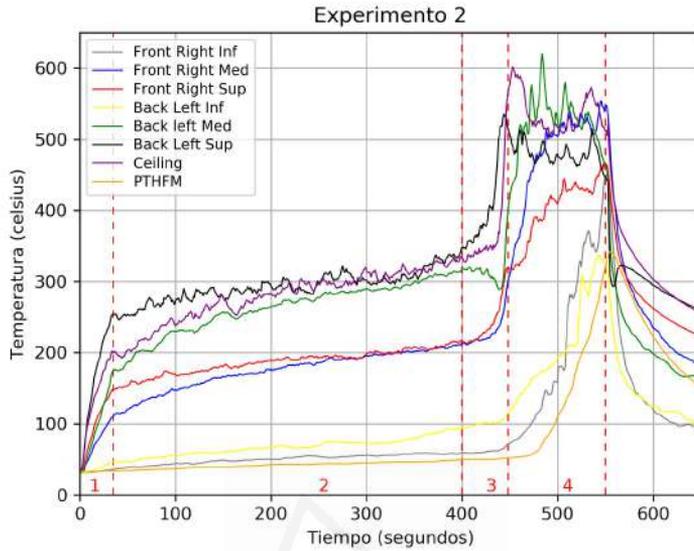
	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
<b>Etapa 1</b>	90.20	100	100	99.20	99.25
<b>Etapa 2</b>	98.81	94.44	98.23	96.23	97.75
<b>Etapa 3</b>	88.57	97.16	63.26	99.35	96.70
<b>Etapa 4</b>	84.21	100	100	98.01	98.20

### 3.5.2. Experimento y simulación 2

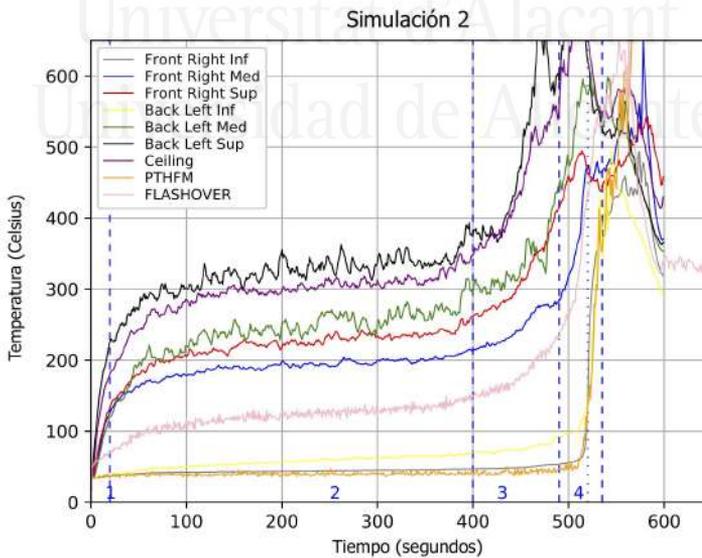
Los datos de los resultados experimentales muestran que el tiempo de la etapa de ignición es mayor que en la simulación (ver figuras 3.22 y 3.23, etapa 1). Por esta razón, el gráfico de convolución WD para la entrada ROI muestra una línea por debajo de 45 grados en la etapa 1. Esto último revela que la tasa de liberación de calor de la simulación es mayor que la del experimento para esta etapa.

Al igual que en el experimento 1, los datos de los sensores de techo y de la parte frontal derecha a nivel medio (colores morado y azul) revelan diferencias entre el experimento y la simulación en el estado 2. Desde el final de la etapa 1 hasta 250 segundos aproximadamente, la liberación de calor en el experimento es menor que en la simulación. Esto se representa como una distribución de puntos por debajo de una línea (imaginaria) de 45 grados en la etapa 2 del gráfico de la convolución WD para imágenes obtenidas con la entrada ROI (ver figura 3.24). Aunque la mayoría de las imágenes en este intervalo han sido bien clasificadas dentro de la etapa 2 utilizando imágenes obtenidas mediante la entrada ROI, la falta de precisión es patente (ver figura 3.25). Desde este punto hasta los 350 segundos aproximadamente, la dispersión de los datos en el gráfico de convolución WD para imágenes obtenidas con la entrada ROI (ver figura 3.24), denotan similitud en temperatura y forma. Cuando esto ocurre, la precisión del clasificador disminuye siendo esta es la causa de que los datos se dispersen. En cuanto a la etapa 3, podemos observar que las imágenes se clasifican correctamente cuando se usa la entrada ROI, pero no ocurre lo mismo cuando se utiliza la imagen original (ver figuras 3.24 y 3.25). Desde el comienzo de

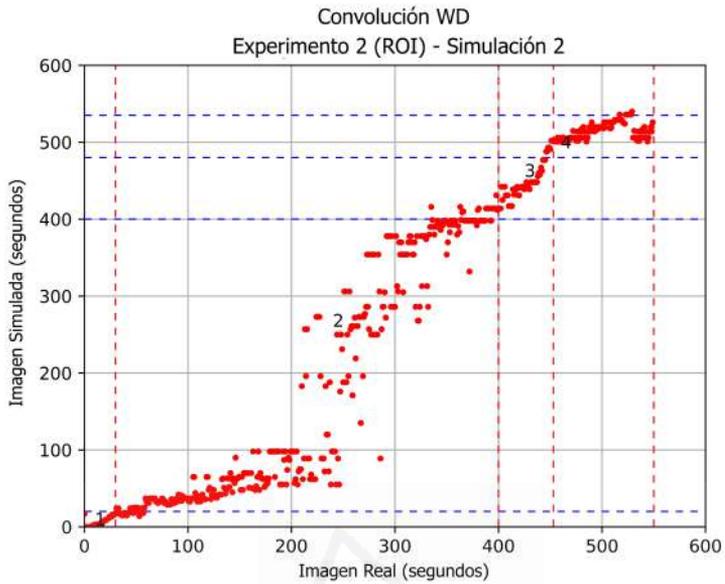
la etapa 3 hasta el punto medio, los valores se pueden identificar en una línea de 45 grados, esto es debido a que el experimento y la simulación tienen la misma tasa de liberación de calor. Por el contrario, desde el punto medio hasta el final de la etapa 3, los datos revelan un cambio rápido en el proceso de combustión del experimento real. El final de esta etapa lo marca el sensor de techo cuando alcanza los 550 °C. Hay que resaltar que, al contrario de lo que ocurría con el experimento 1 y la simulación 1, en este caso los valores del sensor que situado más cerca de la salida del humo (línea azul) son muy próximos en la experimentación y simulación 2, siendo ligeramente superior en el caso de la experimentación. Esto se traduce en una reducción de FNV en esta etapa pudiendo comprobar, que si se hace coincidir este valor con el final de la etapa 3 en la experimentación y simulación los FNV se reducen a cero y por lo tanto el TPR y PPV pasan a ser del 100 %. La etapa 4 presenta una estabilización de temperatura para los sensores superiores, mientras que en los sensores intermedios e inferiores la temperatura continúa aumentando. En este caso, se sitúa el sensor PTHFM en la parte superior de la pared frontal, encima del hueco de ventilación, con el objetivo de medir la radiación térmica que proviene del humo que sale a través de la abertura. Este sensor revela algunas diferencias entre el caso real y la simulación. La pendiente más alta para el PTHFM en la simulación es una consecuencia de una mayor tasa de liberación de calor, debido a que este recibe más radiación del humo que sale al exterior. La segunda condición de *flashover* se alcanza durante esta etapa cuando el sensor de *flashover* registra 454 °C (línea de color rosa, ver figura [3.23](#)). La línea de puntos por debajo de 45 grados en la etapa 4 para imágenes obtenidas con la entrada ROI, revela una tasa de liberación de calor más baja para el experimento. Los datos obtenidos revelan que la convolución WD clasifica correctamente las imágenes de esta etapa utilizando la entrada ROI. No obstante, no ocurre lo mismo con la entrada IMAGE, ya que se obtiene una clasificación menos precisa para este caso específico.



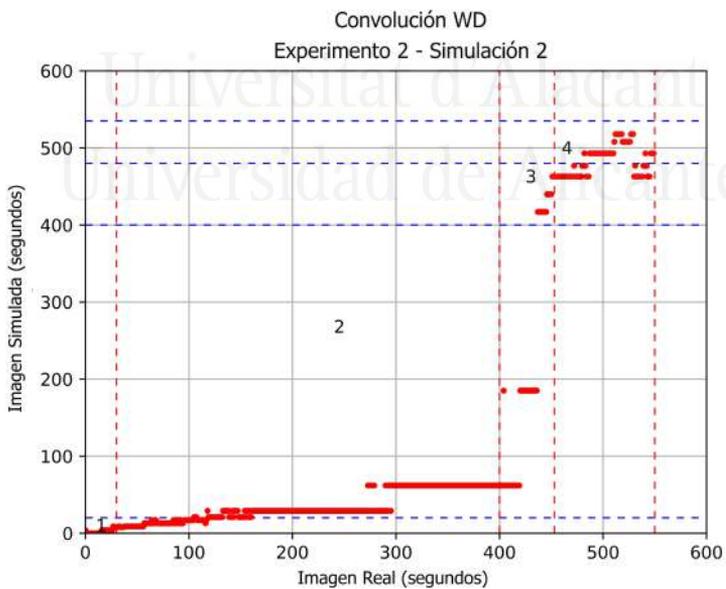
**Figura 3.22:** Datos de los sensores del experimento 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas de trazos rojos.



**Figura 3.23:** Datos de los sensores en la simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas azules.



**Figura 3.24:** Convolución WD entre las imágenes de la cámara térmica (ROI) en el experimento 2 y las imágenes de la simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas.



**Figura 3.25:** Convolución WD entre las imágenes de la cámara térmica (IMAGE) en el experimento 2 y las imágenes de simulación 2. Los números 1, 2, 3 y 4 representan diferentes etapas delimitadas por líneas discontinuas.

De manera similar al experimento y la simulación 1, se han calculado los valores de la matriz de confusión, TPR, TNR, PPV, NPV y ACC, para la imagen original y las imágenes obtenidas con la entrada ROI (ver tablas 3.10, 3.11, 3.12 y 3.13). En este caso, la etapa 1 para imágenes ROI presenta valores de sensibilidad más bajos. Esto es debido a la cantidad de falsos negativos consecuencia de las diferencias en la combustión inicial entre el experimento y la simulación. A pesar de esto, el resto de los valores para esta etapa pueden considerarse excelentes (ver etapa 1 en la tabla 3.7). Los valores de PPV para las imágenes originales en la etapa 1 son más bajos que para las imágenes obtenidas con la entrada ROI, aunque estos resultados no pueden atribuirse únicamente al método aplicado. Para este experimento, se ha establecido como el final de la etapa de ignición cuando la pendiente de la línea que representa los sensores empieza a disminuir. Ajustando estos valores es posible obtener mejores resultados en la etapa 1, ya que se reducirían el número de falsos positivos. La etapa 2 presenta excelentes valores con la entrada ROI. Al igual que en el experimento y simulación 1, se puede observar que la tasa de liberación de calor para el experimento es menor que en la simulación en la etapa 2 (ver figuras 3.22 y 3.23). En la etapa 3, la clasificación a partir de imágenes originales es menos precisa que con la entrada ROI. La etapa 4 presenta buenos valores para ambos casos. En líneas generales, se puede observar que la aplicación del método descrito usando la entrada ROI, proporciona una precisión excelente en la comparación de las imágenes térmicas reales con las simuladas.

**Tabla 3.10:** Matriz de confusión para el experimento 2 (ROI) y la simulación 2. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.

	<b>R1</b>	<b>R2</b>	<b>R3</b>	<b>R4</b>
<b>S1</b>	33	15	0	0
<b>S2</b>	3	333	0	0
<b>S3</b>	0	15	45	0
<b>S4</b>	0	0	6	96

**Tabla 3.11:** Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 2 (ROI) y simulación 2.

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
<b>Etapa 1</b>	91.67	97.06	68.75	99.40	96.70
<b>Etapa 2</b>	91.73	98.36	99.11	85.71	93.96
<b>Etapa 3</b>	88.23	96.97	75.00	98.76	96.15
<b>Etapa 4</b>	100	98.67	94.12	100	98.90

**Tabla 3.12:** Matriz de confusión para el experimento 2 (IMAGE) y la simulación 2. R1, R2, R3 y R4 representan las diferentes etapas en el experimento. S1, S2, S3 y S4 son las etapas en la simulación.

	R1	R2	R3	R4
<b>S1</b>	36	79	0	0
<b>S2</b>	0	286	36	0
<b>S3</b>	0	0	17	47
<b>S4</b>	0	0	0	49

**Tabla 3.13:** Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para el experimento 2 (IMAGE) y simulación 2.

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
<b>Etapa 1</b>	100	80.63	31.30	100	85.64
<b>Etapa 2</b>	78.36	80.54	88.82	65.35	79.09
<b>Etapa 3</b>	32.07	90.54	26.56	92.59	84.90
<b>Etapa 4</b>	51.40	100	100	90.62	91.45

### 3.6. Conclusiones

En este capítulo se ha propuesto un método para sintetizar imágenes térmicas con el objetivo de utilizarlas para la predicción del fenómeno *flashover*. También se ha desarrollado una metodología para validar las imágenes obtenidas (mediante una comparación cuantitativa) que incluyen imágenes originales y las obtenidas mediante la entrada ROI y el uso de la distancia Wasserstein.

Una vez analizados los resultados presentados, es posible afirmar que se puede utilizar el método propuesto en este trabajo para obtener imágenes sintéticas del humo fuera del recinto que sustituyan a las obtenidas con una TC con el objetivo de poder usarlas para crear modelos de predicción. El método presentado para la clasificación de las imágenes en diferentes estadios utilizando la convolución WD y la entrada ROI revela una alta precisión para realizar comparaciones cuantitativas. De hecho, los datos de los sensores en la experimentación y en la simulación coinciden con los resultados del método propuesto (ver gráficos 3.20 y 3.24). Hay que decir que surge cierta incertidumbre cuando la intensidad y las formas de las imágenes son muy similares durante un período de tiempo continuo (estadio 2), en este caso la precisión del método disminuye. Además de lo anterior, con el método propuesto es posible conocer en qué intervalos de la comparación la tasa de liberación de calor de la simulación es mayor o menor que en el caso real y viceversa. Sin embargo, cuando se utilizan las imágenes originales (IMAGE), la convolución WD no revela el mismo grado de precisión lo que dificulta la comparación. Los resultados obtenidos sugieren que es posible realizar una clasificación de imágenes precisa en los diferentes intervalos, utilizando imágenes de una TC tomadas desde diferentes distancias y posiciones utilizando la entrada ROI.



Universitat d'Alacant  
Universidad de Alicante

# Método de predicción del flashover

---

En este capítulo se trata la predicción del fenómeno *flashover* utilizando técnicas de inteligencia artificial. El capítulo se estructura de la siguiente manera: en la sección [4.1](#) se introducen los temas a tratar en este capítulo; el apartado [4.2](#) describe el modelo utilizado para la predicción del *flashover*; la sección [4.3](#) muestra el método experimental para validar el modelo; en el apartado [4.4](#) se presentan y discuten los resultados obtenidos; finalmente, el apartado [4.5](#) muestra las conclusiones de este capítulo.

## 4.1. Introducción

En el capítulo [2.5](#), se realizó un estudio para evaluar el estado del arte de la predicción del *flashover* y se pudo comprobar que existen diferentes situaciones relacionadas con incendios confinados en los que se aplican técnicas de inteligencia artificial para realizar predicciones. Sin embargo, hay que destacar que hasta donde se ha investigado no se encontraron trabajos en los que se utilicen cámaras térmicas, para predecir el *flashover*, aplicando estas técnicas.

Por otro lado, en el apartado [3.3](#) se usó la distancia Wasserstein, en el método de validación, para clasificar las imágenes en las diferentes etapas

en las que se dividió la curva de fuego (ignición, crecimiento, *flashover*, incendio totalmente desarrollado y decaimiento), y poder comparar así ambos conjuntos de datos (real y sintético). De la aplicación de la distancia Wasserstein, con el propósito mencionado anteriormente, se llegó a la conclusión de que existe cierta incertidumbre cuando se mantiene una temperatura durante un período de tiempo en el interior del recinto (ver [3.18](#) y [3.20](#), etapa 2). Esto último nos indica que, las etapas o zonas de una etapa en las que se cumpla esta condición no pueden ser consideradas como candidatos para realizar una predicción temporal fiable utilizando las imágenes obtenidas, puesto que estas inducen a error debido a su parecido.

En base a lo expuesto anteriormente, y teniendo en cuenta que es posible dividir la curva de fuego en diferentes etapas con la información proporcionada por los sensores colocados en el interior del recinto (ver [3.3](#)), es lógico pensar que se puede establecer una relación directa entre la información de los sensores y las imágenes capturadas desde el exterior del recinto con la cámara de visión térmica, con el objetivo de utilizar estas para establecer en qué etapa se encuentra la evolución del incendio. Para estudiar este punto, se ha decidido aplicar los modelos ocultos de Markov (HMM, *Hidden Markov Models*) con el objetivo de comprobar si es posible utilizar los estados ocultos detectados por el modelo, a partir de las imágenes de la cámara térmica, en la predicción del fenómeno *flashover*.

El modelo oculto de Markov fue desarrollado por Baum et al. [\[12\]](#), [\[13\]](#) y sus colegas del Instituto de Análisis de Defensa en Princeton en 1966. Un modelo oculto de Márkov o HMM es un modelo estadístico en el que se asume que el sistema a modelar es un proceso de Márkov de parámetros desconocidos. El objetivo es determinar los parámetros desconocidos (u ocultos, de ahí el nombre) de dicha cadena a partir de los parámetros observables. Estos modelos (HMM) se basan en aumentar la cadena de Markov, que fueron utilizadas por primera vez por Markov et al. [\[53\]](#) en 1913 (traducción de Markov 2006), para predecir si la próxima letra en Eugene Onegin (novela rusa del autor Pushkin) sería una vocal o una consonante. Una cadena de Markov es un modelo que nos proporciona in-

formación sobre las probabilidades de las secuencias de variables aleatorias (estados), cada uno de los cuales puede tomar valores de un conjunto. Estos conjuntos pueden ser palabras, etiquetas o símbolos que representen cualquier cosa, como el clima. En la figura 4.2 (ejemplo de un modelo de Markov para la predicción del *flashover* con dos estados ocultos), la cadena de Markov estaría compuesta por las probabilidades iniciales de que se dé un estado *no flashover* o *flashover* ( $\pi$ ) y las probabilidades de transición entre los dos estados, *no flashover* y *flashover* ( $A$ ). Formalmente la cadena de Markov queda determinada por los componentes que se muestran en la tabla 4.1.

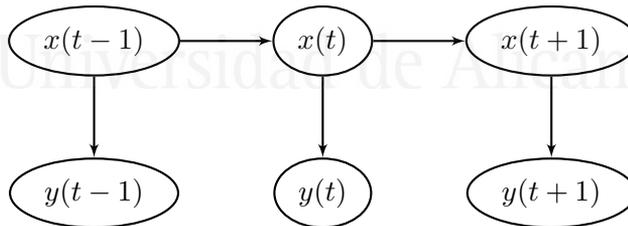
$Q = q_1 q_2 \dots q_N$	Un conjunto de $N$ estados
$A = a_{11} \dots a_{ij} \dots a_{NN}$	Una matriz de transición de probabilidad $A$ , que representa la probabilidad de pasar de un estado $i$ a un estado $j$ , tal que $\sum_{j=1}^N a_{ij} = 1 \forall i$
$\pi = \pi_1, \pi_2, \dots, \pi_N$	Una distribución de probabilidad inicial sobre los estados. $\pi_i$ es la probabilidad con la que la cadena de Markov comenzará en el estado $i$ . Algunos estados $j$ pueden tener $\pi_j = 0$ , esto significa que no pueden ser estados iniciales. Se cumple que $\sum_{i=1}^N \pi_i = 1$

**Tabla 4.1:** Parámetros de una cadena de Markov

Hay que tener en cuenta que una cadena de Markov hace una suposición muy fuerte, de manera que, si se quiere predecir el futuro en una secuencia determinada, lo único importante es el estado actual (propiedad de Markov). Esto quiere decir que los estados anteriores no tienen ningún impacto en la predicción debido a que, toda la información necesaria se recoge en el estado actual. Volviendo al ejemplo del *flashover* con dos estados ocultos, según la propiedad de Markov el modelo haría una predicción del frame  $t+1$  sin saber cómo es el frame  $t-1$ , únicamente tendría en cuenta el estado actual,  $t$ . Formalmente esto último se podría representar de la siguiente manera:

$$\text{Propiedad de Markov: } P_{(q_i=a|q_1\dots q_i)} = P_{(q_i=a|q_i)} \quad (4.1)$$

Una cadena de Markov es útil cuando queremos conocer la probabilidad para una secuencia de eventos que se pueden observar. No obstante, en ocasiones puede darse el caso de que los eventos en los que estamos interesados estén ocultos, por lo tanto, no pueden ser observados directamente. Poniendo como ejemplo el caso del *flashover*, la secuencia observable está compuesta por las imágenes obtenidas con la cámara de visión térmica (frames, ver figura 4.2), mientras que los estados en los que se divide la curva de fuego, permanecen ocultos al observador. En un modelo oculto de Markov se contemplan tanto los eventos que son visibles al observador como los ocultos. Por lo tanto, en un HMM podemos encontrar los parámetros que se muestran en la tabla 4.2. En un modelo oculto de primer orden se hacen dos suposiciones. La primera, al igual que en las cadenas de Markov, es que la probabilidad de un estado particular únicamente depende del estado anterior (ver 4.1). La figura 4.1 representa en un diagrama la arquitectura de un HMM,  $x(t)$  e  $y(t)$  son los valores de las variables ocultas y observadas respectivamente y las flechas indican dependencias condicionales. Se puede observar que el valor de  $x(t)$  depende únicamente del valor de  $x(t - 1)$ , cumpliéndose así la primera suposición, a esto se le conoce también como Propiedad de Markov, como se vio anteriormente.



**Figura 4.1:** Arquitectura HMM

La segunda suposición hace referencia a que la probabilidad de una observación  $o_i$ , depende únicamente del estado que produce esa observación  $q_i$  y no de otros estados u otras observaciones.

**Independencia de la salida:**  $P_{(o_i|q_1\dots q_i,\dots,q_T,o_1,\dots,o_i,\dots,o_T)} = P_{(o_i|q_i)}$  (4.2)

$Q = q_1 q_2 \dots q_N$	Un conjunto de $N$ estados
$A = a_{11} \dots a_{ij} \dots a_{NN}$	Una matriz de transición de probabilidad $A$ , que representa la probabilidad de pasar de un estado $i$ a un estado $j$ , tal que $\sum_{j=1}^N a_{ij} = 1 \forall i$
$O = o_1 o_2 \dots o_T$	Una secuencia de $T$ observaciones
$B = b_i(o_t)$	Una secuencia de probabilidades de observación, también llamadas probabilidades de emisión, cada una de las cuales expresa la probabilidad de que se genere una observación $O_t$ generada desde un estado $i$
$\pi = \pi_1, \pi_2, \dots, \pi_N$	Una distribución de probabilidad inicial sobre los estados. $\pi_i$ es la probabilidad con la que la cadena de Markov comenzará en el estado $i$ . Algunos estados $j$ pueden tener $\pi_j = 0$ , esto significa que no pueden ser estados iniciales. Se cumple que $\sum_{i=1}^N \pi_i = 1$

**Tabla 4.2:** Parámetros de un modelo oculto de Markov

En referencia a los tipos problemas que se pueden abordar con este modelo, Rabiner et al. [65] introduce la idea en 1989 de que los modelos ocultos de Markov deben ser caracterizados en tres problemas fundamentales:

- **Problema 1 (likelihood, probabilidad):** Dado un HMM conocido  $\lambda = (A, B)$  y una secuencia  $O$ , ¿cuál es la probabilidad de que ocurra la secuencia  $O$ ? Determinar  $P(O|\lambda)$ .
- **Problema 2 (decoding, decodificar):** Dado un modelo  $\lambda = (A, B)$  y una secuencia  $O$  conocidos, ¿cuál es la secuencia óptima de estados ocultos?
- **Problema 3 (learning, aprendizaje):** Dada la secuencia  $O$  y el número de estados ocultos, ¿cuál es el modelo óptimo que maximiza la probabilidad de  $O$ ? Aprendizaje de los parámetros  $A$  y  $B$ .

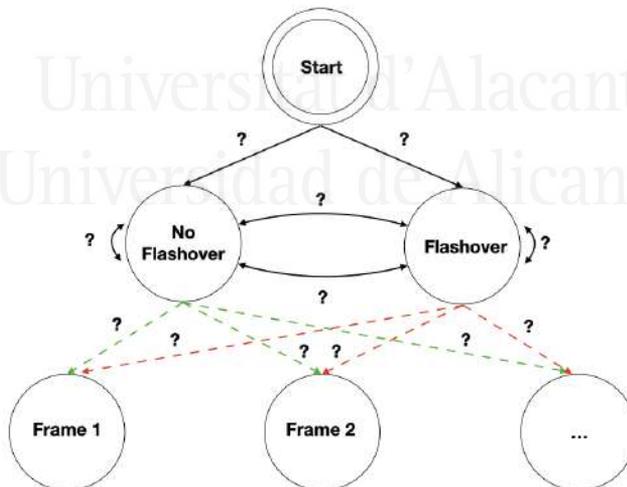
El primer y el segundo problema pueden resolverse mediante los algoritmos de programación dinámica conocidos como algoritmo de avance-retroceso y algoritmo de Viterbi [26, 76], respectivamente. El último puede

resolverse mediante un algoritmo iterativo de expectativa-maximización (EM), conocido como algoritmo de Baum-Welch [13].

En el siguiente apartado se explica los pasos que se han seguido para obtener el modelo de predicción para el *flashover* basado en los modelos ocultos de Markov.

## 4.2. HMM para predicción del flashover

Predecir el fenómeno del *flashover* utilizando los modelos ocultos de Markov supone en primer lugar identificar los estados ocultos en el modelo. En el capítulo anterior se podían identificar las etapas en las que se dividía la curva de fuego, gracias a los diferentes sensores distribuidos en el interior del recinto confinado. No obstante, en una intervención real no disponemos de estos sensores para identificar las diferentes etapas. La única información, será la obtenida por la cámara de visión térmica desde el exterior del recinto (frames, ver figura 4.2).



**Figura 4.2:** La imagen muestra un modelo para el caso propuesto de predicción del *flashover* con dos estados ocultos y diferentes estados observables.

La cantidad de información que obtenemos de la cámara térmica está

definida por la frecuencia de adquisición de imágenes. Independientemente de las características técnicas de la cámara, la evolución de un incendio de interior en intervalos inferiores a 1 segundo es casi imperceptible. Por este motivo, se ha considerado realizar el análisis de las imágenes que se obtienen con la cámara en intervalos de 1 segundo.

Hay que tener en cuenta que la temperatura ambiente va a depender de varios factores, como por ejemplo la estación del año en la que nos encontremos, el clima, la situación geográfica, etc. A esto hay que añadir que, en el campo de visión de la cámara térmica, además del humo que sale del recinto, pueden verse incluidas las superficies de diferentes materiales cuya información no es relevante para la predicción del fenómeno *flashover*. Por este motivo se ha considerado también, antes de entrenar el clasificador, realizar un tratamiento en la imagen térmica para eliminar aquellos datos que pueden ser generadores de ruido. Para este estudio se ha considerado un umbral, de manera que todos los valores por debajo de este valor límite son igualados a este. Con esto se consigue eliminar todo el ruido de la imagen debido a las condiciones ambientales y objetos con distinta emisividad situados en el campo de visión de la cámara. Por lo tanto, en los resultados obtenidos que se muestran en [4.4](#) se diferencian aquellos en los que se ha realizado tratamiento de la imagen térmica de los que no. En el proceso de toma de decisiones, se han analizado los dos métodos efectuando la elección final estudiando la curva que hace referencia a la Característica Operativa del Receptor (ROC, *Receiver Operating Characteristic*) resultante y el área bajo la curva ROC (AUC, *Area Under the Curve*). Los resultados de este análisis pueden consultarse en el apartado [4.4](#).

#### 4.2.1. Vector de características de la imagen

Para poder obtener el modelo de Markov óptimo a partir de las observaciones obtenidas de las simulaciones, es necesario extraer un vector de características de cada imagen de la secuencia. Para el caso que nos ocupa se han considerado cuatro vectores de características distintos para poder evaluar su funcionamiento. Por una parte, se ha considerado acumular los

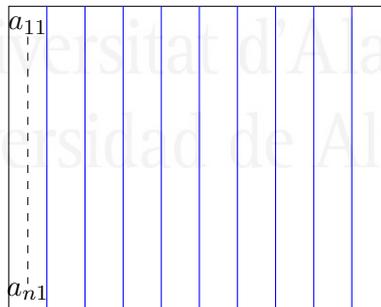
valores de cada columna de la imagen (Sum-Col, ver ecuación 4.3), después de aplicar las transformaciones comentadas anteriormente para obtener el vector de características de los datos obtenidos (ver ecuación y figura 4.4).

$$b_{ij} = \sum_{i=1}^N a_{ij} \quad (4.3)$$

La ecuación que representa de la formación del vector de características en este caso viene definida por 4.3, donde  $b_{ij}$  representa el valor de una columna del vector de características de una imagen para una secuencia determinada y  $a_{ij}$  representa el valor de un pixel de la imagen obtenido con la cámara térmica. Por otra parte, también se ha considerado estudiar la suma de las intensidades de cada fila (Sum-Fila), siendo la ecuación que define el vector características 4.4.

$$b_{ij} = \sum_{j=1}^N a_{ij} \quad (4.4)$$

Matriz de intensidades



Vector de características

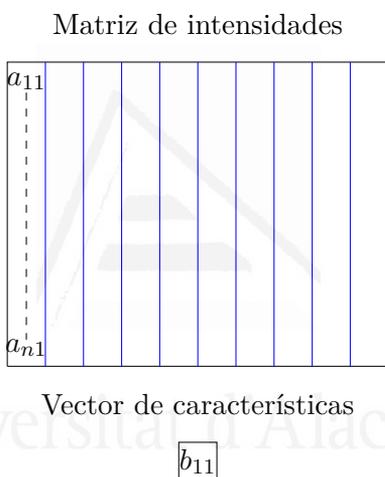


**Figura 4.3:** Representación de la obtención del vector de características a partir de la imagen observada sumando las intensidades de cada columna de la imagen obtenida con la cámara térmica.

Otro vector de características que se ha considerado es el formado por la desviación típica ( $\Sigma$ ) de cada imagen (ver ecuación 4.5). En este caso

cada fila del vector de características contiene un único valor, es decir que este estará formado por tantas filas como imágenes tenga la secuencia y una columna. Como última opción se ha utilizado un vector de características formado por la distancia Wasserstein, de cada imagen a la imagen que inicia la secuencia. El vector de características en este último caso se estructura igual que en el caso anterior sustituyendo el valor de  $\Sigma$  por el valor WD.

$$b_{i1} = \Sigma = \sqrt{\frac{\sum_{i=1}^{N_{filas}} \sum_{j=1}^{N_{columnas}} (a_{ij} - \bar{a})^2}{N_{total}}} \quad (4.5)$$



**Figura 4.4:** Representación de la obtención del vector de características a partir de la imagen observada obteniendo la desviación típica de la imagen.

### 4.2.2. Elección del clasificador

Llegados a este punto, es importante hacer un análisis de los datos que vamos a tratar puesto que de esto va a depender el modelo a utilizar. Los datos obtenidos con la cámara de visión térmica son adquiridos en intervalos de un segundo. Aunque en el estudio de cada dato de cada frame por separado estos pueden ser clasificados como datos discretos, en el análisis de los datos para la elección del modelo estos han de verse como datos continuos en su conjunto, debido a que el intervalo de tiempo entre dos frames podría disminuirse incrementando así la precisión de la medida. Véase

que entre dos frames distintas hay infinitas posibilidades de adquisición de datos, aunque en este caso este número está limitado por la frecuencia de adquisición de la cámara (30 Hz), con lo que como máximo podríamos obtener 30 frames por segundo, como se ha comentado anteriormente. Teniendo este punto claro, se han considerado evaluar los modelos ocultos de Markov para las distribuciones Gaussianas (GaussianHMM, *Hidden Markov Model with Gaussian Emissions*) y las distribuciones de mezcla Gaussianas [31] (GMMHMM, *Gaussian Mixture Emissions*), dado que la curva de fuego es asemejable a este tipo de distribuciones contando con todas las etapas en su totalidad (inicio, desarrollo, flashover, totalmente desarrollado y decaimiento). La principal diferencia entre las dos técnicas radica en que en GaussianHMM las probabilidades de emisión proceden de una sola densidad Gaussianas y en GMMHMM estas probabilidades proceden de una mezcla de distintas distribuciones Gaussianas, en cuyo caso la densidad es una combinación lineal de densidades distribuciones Gaussianas de componentes. Para evaluar los distintos clasificadores se usa el vector de características Sum-Col descrito en el apartado anterior, los resultados se pueden consultar en el apartado 4.4.

### 4.2.3. Entrenamiento y comprobación del modelo

Para poder realizar el entrenamiento y comprobación de los modelos obtenidos, se han utilizado los datos de 65 simulaciones llevadas a cabo para tal fin, de las cuales en 23 no se produce el *flashover* y en las 42 restantes sí. Para marcar la diferencia en los casos de incendios simulados, se han considerado variar los materiales para el continente, dimensiones del espacio confinado, tipos de combustibles, localización y tamaño de la abertura de ventilación, tamaño del fuego y su localización. En la tabla B.1 se puede observar con más detalle la configuración de cada simulación. Las columnas muestran los siguientes valores: N°SIM, número de la simulación; MAT, tipo de material empleado (AB *adiabático*, AC *acero*); DIMENSIONES, dimensiones del recinto x,y,z en cm; VENT(1), dimensiones del hueco de ventilación en cm; VENT(2), localización del hueco de ventilación en el espacio creado en cm; COMB(1), tipo de combustible; COMB(2), tamaño

del combustible en cm (superficie expuesta); COMB(3), localización del combustible en cm; DUR, duración de la simulación en segundos; FLASH, si valor es “0”, no se ha producido *flashover*, si el valor es distinto de “0” muestra en qué instante se produce el *flashover*.

En el apartado 4.1 se expusieron los problemas fundamentales en los que deben ser caracterizados los modelos ocultos de Markov. En el caso que nos ocupa, disponemos de una secuencia y un número de estados ocultos y el objetivo es encontrar el modelo óptimo que maximice la probabilidad de la secuencia observada para realizar predicciones posteriormente, por lo que podemos decir que la situación es similar al problema 3. El problema que se presenta es: ¿qué secuencia o secuencias se han de introducir para encontrar el modelo óptimo? Dado que para esta investigación se ha optado por estudiar los modelos ocultos para la predicción del *flashover* (ver apartado 4.1), parece lógico pensar que la secuencia elegida para entrenar el modelo ha de incluir como mínimo los dos estados ocultos que queremos que detecte, *flashover* y *no flashover*. Sin embargo, en esta investigación se ha querido estudiar también el efecto que tiene el entrenamiento del modelo con una secuencia en la que no se ha producido el *flashover* y la combinación de esta con una en la que si se ha producido. Para llevar esto a cabo, se han seleccionado 4 simulaciones de entre las 65 que se muestran en la tabla B.1, AI-1, AI-24, AI-25 y AI-41. La elección de estas simulaciones responde a criterios de evolución del incendio de interior, basándonos en los datos que nos proporcionan los sensores situados en el centro del techo del recinto confinado y en el suelo (ver figuras 4.5, 4.6, 4.7 y 4.8).

Una vez elegidas las secuencias se procede a crear los modelos ocultos de Markov diferentes, utilizando las variaciones que se han descrito en este apartado, para estudiar su comportamiento. Todas las secuencias están formadas por vectores de características de las imágenes obtenidas de las simulaciones obtenidas cada segundo (1 frame/segundo). Para entrenar el primer conjunto de modelos se utilizará una secuencia formada 90 frames de la simulación AI-1 (ver figura 4.5), en la que no se ha producido el fenómeno *flashover*. El segundo conjunto se entrena con la secuencia formada

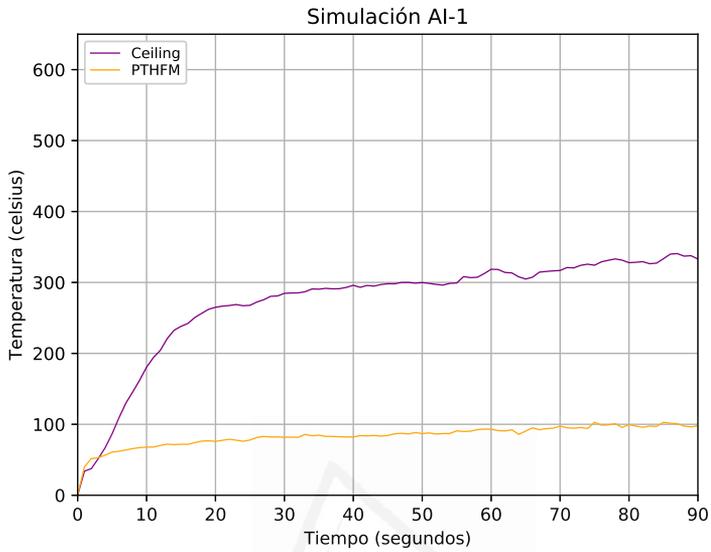


Figura 4.5: Evolución del incendio en la simulación AI-1.

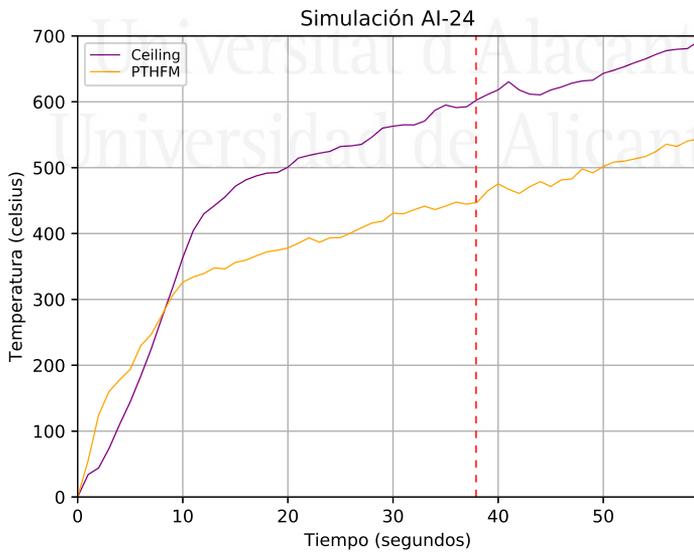
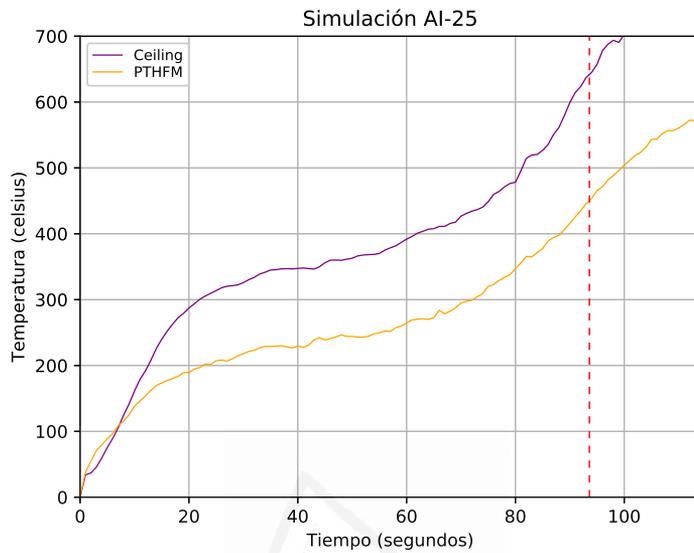
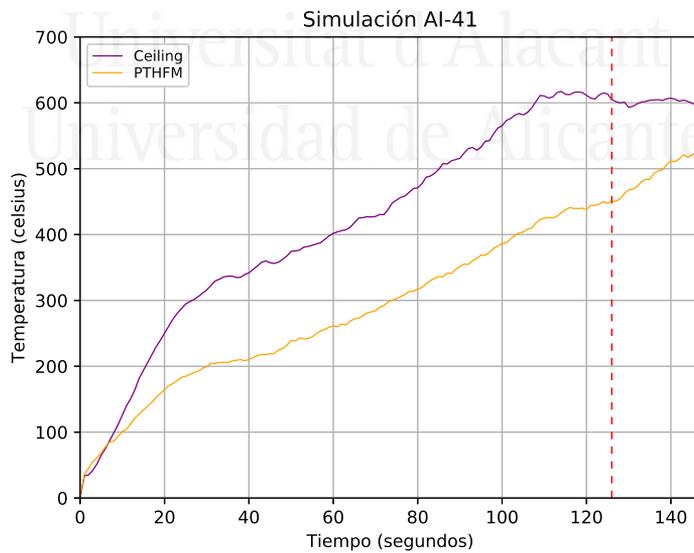


Figura 4.6: Evolución del incendio en la simulación AI-24. La línea discontinua de color rojo muestra el momento en el que el *flashover* se produce.



**Figura 4.7:** Evolución del incendio en la simulación AI-25. La línea discontinua de color rojo muestra el momento en el que el *flashover* se produce.



**Figura 4.8:** Evolución del incendio en la simulación AI-41. La línea discontinua de color rojo muestra el momento en el que el *flashover*.

a partir de 59 frames de la simulación AI-24, en la que se ha producido el *flashover* en el segundo 37.9. Se utilizará la secuencia que se obtiene de la simulación AI-25 para entrenar el tercer conjunto de modelos, con *flashover* según la lectura de los sensores en el segundo 93.6 y finalmente, el último conjunto de modelos se crea a partir del entrenamiento de dos secuencias obtenidas de las simulaciones AI-24 y AI-41, esta última formada por 147 frames y *flashover* en el segundo 126. En primer lugar, se utiliza la secuencia obtenida de la simulación AI-24 para averiguar qué vector de características de los propuestos en este apartado funciona mejor. Atendiendo a las combinaciones posibles según los parámetros comentados anteriormente, se analizan un total de 48 modelos diferentes entrenados con la secuencia de AI-24 teniendo en cuenta el tratamiento de la imagen previo y variando entre los diferentes tipos de vectores de características. Una vez que se ha obtenido el vector de características que mejor se adapte al problema de entre los propuestos, se utilizará para los modelos de las otras secuencias propuestas para analizarlas y discutir los resultados (ver apartado [4.4](#)).

Debido a la cantidad de modelos e información a tratar, es necesario contar con una herramienta que nos permita diferenciar los modelos que se presentan como posibles candidatos para poder estudiarlos detenidamente. Por este motivo, se ha decidido utilizar la curva ROC (ver figura [4.9](#)) para realizar esta tarea. En la teoría de detección de señales, una curva ROC es una representación gráfica de la ratio de verdaderos positivos (VPR, sensibilidad, ver ecuación [4.6](#)) frente al ratio de falsos positivos (FPR, 1-especificidad, ver ecuación [4.7](#)) para un sistema clasificador binario según se varía el umbral de discriminación. En el caso que nos ocupa, al estar estudiando modelos de Markov con dos estados ocultos, cuya salida será 0 cuando no se detecte el *flashover* y 1 cuando se identifique el *flashover* en un frame, se cumple la condición de ser un sistema binario para poder utilizar esta herramienta. En [4.3](#) se muestra la configuración de la matriz de confusión y como se obtiene el ratio de verdaderos positivos y la ratio de falsos positivos a partir de esta (ver ecuaciones [4.6](#) y [4.7](#)).

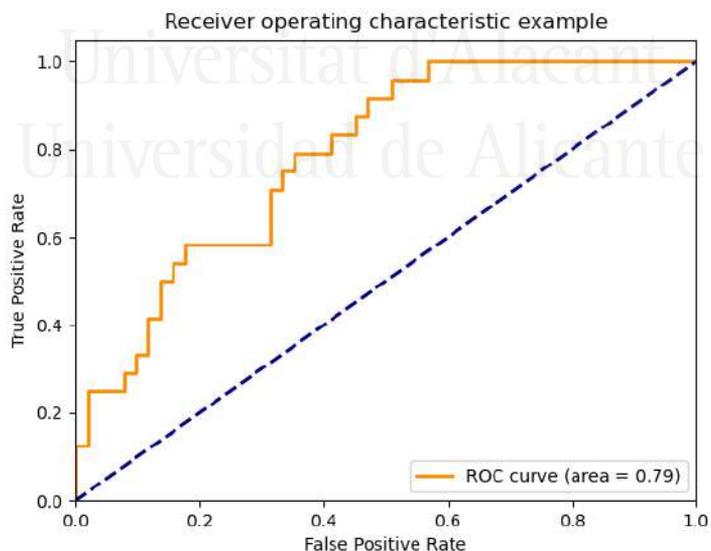
$$VPR = \frac{VP}{P} = \frac{VP}{VP + FN} \quad (4.6)$$

$$FPR = 1 - \frac{VN}{N} = 1 - \frac{VN}{VN + FP} \quad (4.7)$$

		Observación	
		Positivo	Negativo
Predicción	Positivo	VP	FP
	Negativo	FN	VN

**Tabla 4.3:** Configuración de la Matriz de confusión

Para interpretar los resultados de la prueba se ha utilizado el área bajo la curva ROC (AUC, *area under the curve*), que es el estadístico por excelencia para medir la capacidad discriminante de una prueba. También para comparar pruebas entre sí y determinar cuál es la más eficaz.



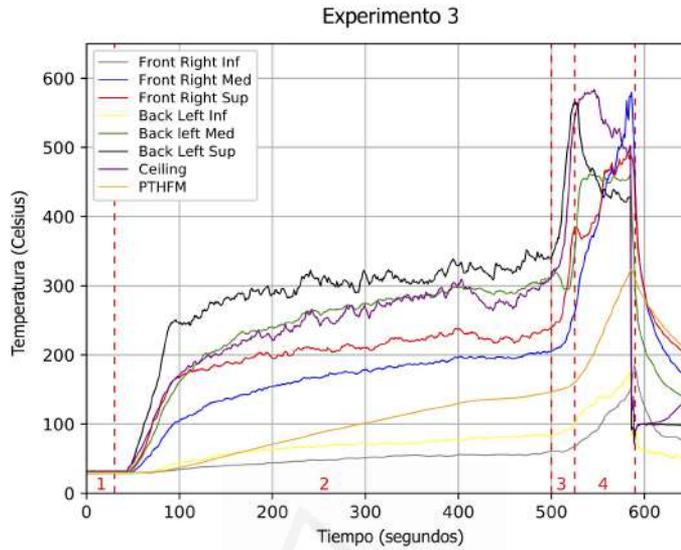
**Figura 4.9:** Curva ROC

En este estudio se han analizado dos tipos de curvas ROC y sus res-

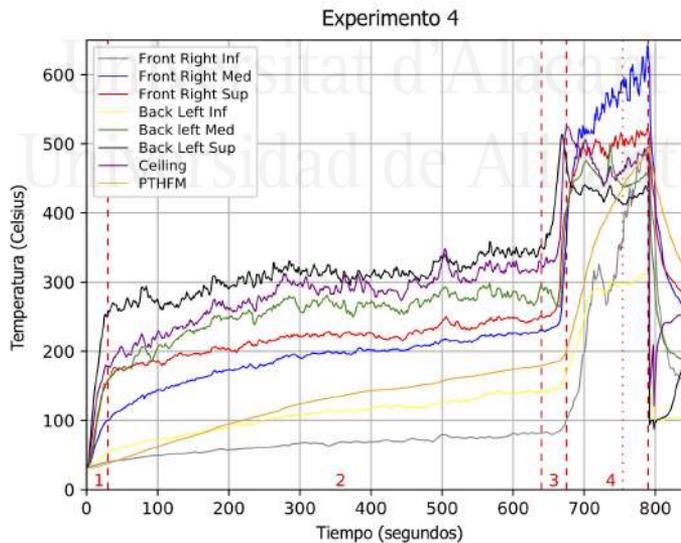
pectivas áreas. En primer lugar, se ha considerado analizar la curva ROC que se obtiene a partir de los datos observables de las simulaciones y las probabilidades (scores) que resultan de aplicar el modelo sobre las simulaciones. Por otro lado, se han estudiado las curvas ROC obtenidas de la concatenación de todas las observaciones (frames) de las simulaciones y la concatenación de las probabilidades de todos los frames. El objetivo es utilizar el método más preciso de los dos presentados para poder evaluar correctamente los modelos. Este paso se realiza para los modelos entrenados con las secuencias obtenidas de la simulación AI-24, para el resto de modelos se aplica el más efectivo de los dos. Los resultados pueden consultarse en el apartado [4.4](#).

### 4.3. Método experimental

Para poder comprobar el modelo de predicción, se proponen dos experimentos reales a pequeña escala (ver figuras [4.10](#) y [4.11](#)). Los experimentos son diseñados con las mismas medidas y materiales que en los casos diseñados para la validación del conjunto de datos sintéticos. Para el experimento 3 el combustible fue situado a 6 cm de la pared posterior y a 12.5 cm del lateral izquierdo. En el caso del experimento 4 el combustible se sitúa a 6.5 cm de la pared posterior y a 13.5 cm del lateral izquierdo. Los casos reales están diseñados para que se produzca el *flashover*, desgraciadamente en el experimento 3 el fuego fue sofocado antes de que uno de los sensores (PTHMF, línea naranja en la figura [4.10](#)) marcara el valor deseado, por lo que no se ha considerado utilizarlo en esta investigación. Las imágenes térmicas son obtenidas con la cámara FlirE75 cuyas especificaciones se pueden ver en el apartado [3.4.2](#). Previamente al análisis de las imágenes con el modelo obtenido con objeto de realizar la predicción, a la imagen de la cámara térmica se le aplica el método ROI discutido en el capítulo [3](#), a consecuencia de que como se vio en esta entrada de la imagen real mejora los resultados obtenidos con la distancia Wasserstein. Los resultados de la aplicación del modelo de predicción sobre los experimentos reales pueden consultarse en el apartado [4.4](#).



**Figura 4.10:** Datos de los sensores en la simulación 3. Los números 1,2,3 y 4 representan los diferentes estados, limitados por líneas discontinuas rojas, en los que se ha dividido la curva de fuego.



**Figura 4.11:** Datos de los sensores en la simulación 4. Los números 1,2,3 y 4 representan los diferentes estados delimitados por líneas discontinuas rojas. La línea de puntos en la etapa 4 representa el momento en el que la radiación a nivel de suelo alcanza  $20 \text{ kW/m}^2$ .

## 4.4. Resultados y discusión

En este apartado se muestran los resultados correspondientes a los entrenamientos y comprobación de los modelos creados para encontrar el modelo óptimo usando datos sintéticos y la aplicación de este sobre los casos reales diseñados. Para este trabajo se ha utilizado Python 3.6 para crear los scripts correspondientes y la librería `hmmlearn` de `scikit learn` para crear los modelos ocultos de Markov.

En la tabla [4.4](#) se muestran los resultados de las pruebas realizadas con los clasificadores que se adaptan al problema planteado, debido a que como se comentó en el apartado [4.2](#), el modelo que mejor se adapta es el continuo. En todos los modelos el número de estados ocultos es 2 y se varía entre los tipos de covarianza posibles para ver cuál funciona mejor utilizando la misma secuencia. El método que se utiliza para la elección del clasificador en este punto y los parámetros planteados es la probabilidad de total de la secuencia (score), siendo el clasificador óptimo el que tenga un score más elevado. Si bien, hay que tener cuidado en este punto puesto que esto no es garantía de que el clasificador arroje los resultados esperados. Es necesario analizar los resultados de la predicción para ver qué es lo que está ocurriendo realmente y tomar una decisión en base a estos dos parámetros conjuntamente.

De los dos clasificadores (GaussianHMM y GMMHMM) que se han estudiado, los resultados obtenidos muestran una mayor probabilidad (score) para el GMMHMM utilizando una covarianza diagonal, pero al analizar la predicción vemos que esta no se realiza correctamente, debido a que no predice ningún caso de *flashover* y lo mismo ocurre con la co-varianza esférica. Por lo tanto, de entre los modelos que realizan una predicción correcta, el que mayor probabilidad tiene es el GaussianHMM con co-varianza 'Full' (96 550). Esta configuración es la que se utilizará para la elección del modelo oculto de Markov óptimo para la predicción del *flashover*.

Modelo	Nº estados	Co-varianza	Score	Predicción
GaussianHMM	2	Full	96 550	OK
GaussianHMM	2	Spherical	26 698	OK
GaussianHMM	2	Diagonal	48 626	OK
GaussianHMM	2	Tied	85 997	OK
GMMHMM	2	Full	95 296	OK
GMMHMM	2	Spherical	3 690 794	NO
GMMHMM	2	Diagonal	4 874 264	NO
GMMHMM	2	Tied	95 296	OK

**Tabla 4.4:** Resultados de las pruebas realizadas con los clasificadores continuos de la herramienta hmmlern de Scikit Learn

Como se comentó en el apartado [4.2](#), es necesario determinar el vector de características óptimo y el tratamiento previo de la imagen con el fin de seleccionar el modelo que mejor se adapte al problema. Las tablas [4.5](#) y [4.6](#) muestra los resultados de las diferentes combinaciones que se discutieron en el apartado [4.2](#) para el tratamiento previo de la imagen y para los vectores de características propuestos (WD, desviación típica, suma de las filas y suma de las columnas). En dichas tablas también se ha incluido el análisis del área bajo la curva ROC para ver que técnica resulta más eficiente, teniendo en cuenta las secuencias o teniendo en cuenta cada frame de cada secuencia. Para el primer caso se utiliza la clasificación según las observaciones de la secuencia y las probabilidades de cada secuencia (columna ROC, Secuencia), mientras que en el segundo caso se configura con las observaciones de cada frame de la secuencia y las probabilidades de cada frame de la secuencia (columna ROC, Frame). Para hacer esto último se concatenan los datos procedentes de cada frame en las diferentes secuencias. De los datos obtenidos utilizando la simulación AI-24, podemos observar que los valores del área bajo la curva en los casos en los que se ha utilizado la técnica Frame, son superiores a los valores de aquellos casos en que se ha utilizado la técnica de la secuencia. Esto nos indica, que la técnica (Frame) proporciona datos más precisos de cómo está actuando el clasificador, por este motivo se utilizará esta técnica para la toma de decisiones en la elección del clasificador.

En cuanto al vector de características, analizando los datos del área bajo la curva en las tablas 4.5, y 4.6 vemos que los valores obtenidos cuando se utiliza la distancia Wasserstein y la desviación típica son superiores a los valores cuando se utiliza la suma de las filas o la suma de columnas, por lo tanto, estos dos últimos vectores de características no se tendrán en cuenta en para la elección del clasificador. En cuanto a la distancia Wasserstein y la desviación típica podemos observar que arrojan valores similares. En la tabla 4.5, en la que no se ha realizado tratamiento previo de la imagen, podemos observar valores ligeramente superiores de  $\Sigma$  sobre WD, pero esto puede inducir a error si no se estudia con detenimiento. La desviación típica nos muestra, en un valor, la variación o dispersión de un conjunto de datos. Dado que, como hemos introducido previamente, el sistema puede que se utilice en distintos ambientes, la desviación típica para un frame del mismo incendio no será la misma cuando las condiciones ambientales referentes a la temperatura sean distintas, siendo mayor en el caso en el que haya más diferencia. Esto se debe a que la temperatura máxima para que se produzca el *flashover* tiene que alcanzar cierto valor (550 °C, primera condición de *flashover*) si bien, la temperatura ambiente varía con lo que la diferencia en ambientes fríos es más notable y por tanto el valor de la desviación típica será más elevado para el mismo caso. A esto último hay que añadir que la localización de la cámara en los experimentos reales varía en encuadre y posición. Como resultado, la desviación típica obtendría buenos resultados en imágenes con tratamiento térmico y con mismo encuadre y posición de la cámara. No ocurre lo mismo con la distancia Wasserstein, que como se explicó en el capítulo 3, tiene en cuenta la forma de la imagen y sí que sería posible utilizarla sin tratamiento previo de la imagen y con distinto encuadre y localización de la TC. A esto hay que añadir que, al realizar el tratamiento a la imagen (ver tabla 4.6) se observa que los valores bajo la curva para la distancia Wasserstein son superiores a los de la desviación típica. Teniendo en cuenta todo lo anterior, se decide estudiar los estados ocultos de las secuencias propuestas utilizando el clasificador Gaussiano con Co-varianza 'Full', utilizando la técnica Frame, usando como vector de características la distancia Wasserstein de cada imagen y realizando el tratamiento de imagen previo.

**Tabla 4.5:** Resultados de las pruebas realizadas para determinar el vector de características sin tratamiento de la imagen térmica.

Nº	Sim	EO	ROC	Vector	AUC
1	AI-24	2	Secuencia	WD	0.76
2	AI-24	2	Secuencia	$\Sigma$	0.76
3	AI-24	2	Secuencia	Sum-Fila	0.76
4	AI-24	2	Secuencia	Sum-Col	0.76
5	AI-24	2	Frame	WD	0.85
5	AI-24	2	Frame	$\Sigma$	0.86
6	AI-24	2	Frame	Sum-Fila	0.58
7	AI-24	2	Frame	Sum-Col	0.75
9	AI-25	2	Secuencia	WD	0.77
10	AI-25	2	Secuencia	$\Sigma$	0.77
11	AI-25	2	Secuencia	Sum-Fila	0.48
12	AI-25	2	Secuencia	Sum-Col	0.61
13	AI-25	2	Frame	WD	0.81
14	AI-25	2	Frame	$\Sigma$	0.85
15	AI-25	2	Frame	Sum-Fila	0.52
16	AI-25	2	Frame	Sum-Col	0.48
17	AI-41	2	Secuencia	WD	0.79
18	AI-41	2	Secuencia	$\Sigma$	0.76
19	AI-41	2	Secuencia	Sum-Fila	0.50
20	AI-41	2	Secuencia	Sum-Col	0.53

Continúa en la página siguiente

Continúa en la página anterior

Nº	Sim	EO	ROC	Vector	AUC
21	AI-41	2	Frame	WD	0.80
22	AI-41	2	Frame	$\Sigma$	0.85
23	AI-41	2	Frame	Sum-Fila	0.50
24	AI-41	2	Frame	Sum-Col	0.47
15	AI-24,41	2	Secuencia	WD	0.76
18	AI-24,41	2	Secuencia	$\Sigma$	0.72
19	AI-24,41	2	Secuencia	Sum-Fila	0.47
20	AI-24,41	2	Secuencia	Sum-Col	0.64
21	AI-24,41	2	Frame	WD	0.82
22	AI-24,41	2	Frame	$\Sigma$	0.85
23	AI-24,41	2	Frame	Sum-Fila	0.50
24	AI-24,41	2	Frame	Sum-Col	0.50

**Tabla 4.6:** Resultados de las pruebas realizadas para determinar el vector de características con tratamiento de la imagen térmica.

Nº	Sim	EO	ROC	Vector	AUC
1	AI-24	2	Secuencia	WD	0.76
2	AI-24	2	Secuencia	$\Sigma$	0.75
3	AI-24	2	Secuencia	Sum-Fila	0.44
4	AI-24	2	Secuencia	Sum-Col	0.5
5	AI-24	2	Frame	WD	0.85
6	AI-24	2	Frame	$\Sigma$	0.79
7	AI-24	2	Frame	Sum-Fila	0.56
8	AI-24	2	Frame	Sum-Col	0.74
9	AI-25	2	Secuencia	WD	0.63
10	AI-25	2	Secuencia	$\Sigma$	0.67
11	AI-25	2	Secuencia	Sum-Fila	0.45
12	AI-25	2	Secuencia	Sum-Col	0.50
13	AI-25	2	Frame	WD	0.68

Continúa en la página siguiente

Continúa en la página anterior

Nº	Sim	EO	ROC	Vector	AUC
14	AI-25	2	Frame	$\Sigma$	0.64
15	AI-25	2	Frame	Sum-Fila	0.57
16	AI-25	2	Frame	Sum-Col	0.75
17	AI-41	2	Secuencia	WD	0.70
18	AI-41	2	Secuencia	$\Sigma$	0.68
19	AI-41	2	Secuencia	Sum-Fila	0.55
20	AI-41	2	Secuencia	Sum-Col	0.49
21	AI-41	2	Frame	WD	0.73
22	AI-41	2	Frame	$\Sigma$	0.63
23	AI-41	2	Frame	Sum-Fila	0.52
24	AI-41	2	Frame	Sum-Col	0.75
15	AI-24,41	2	Secuencia	WD	0.66
18	AI-24,41	2	Secuencia	$\Sigma$	0.67
19	AI-24,41	2	Secuencia	Sum-Fila	0.40
20	AI-24,41	2	Secuencia	Sum-Col	0.47
21	AI-24,41	2	Frame	WD	0.69
22	AI-24,41	2	Frame	$\Sigma$	0.69
23	AI-24,41	2	Frame	Sum-Fila	0.76
24	AI-24,41	2	Frame	Sum-Col	0.69

Una vez están claros los parámetros principales del clasificador para la predicción del *flashover*, el siguiente paso es evaluar cómo se comportan las diferentes secuencias seleccionadas para el entrenamiento del modelo. Esto permitirá conocer cómo tiene que ser la secuencia o secuencias que maximicen la probabilidad del modelo. La tabla 4.7 muestra los resultados obtenidos con los modelos confeccionados a partir de las simulaciones propuestas utilizando la configuración del clasificador que se ha explicado anteriormente. En primer lugar, se analiza un modelo creado a partir de una simulación en la que los sensores confirman que no se ha producido el *flashover*, simulación AI-1. Los datos obtenidos revelan que este modelo no es capaz de predecir ningún caso de *flashover* en las simulaciones, lo que descarta la utilización de este tipo de secuencias en la creación del

modelo, por esta razón no se representa en las tablas que se muestran en este apartado. Las secuencias restantes que se analizan son obtenidas de simulaciones en las que se ha producido el fenómeno *flashover* (ver figuras 4.6, 4.7 y 4.8). En este paso se ha considerado estudiar cómo se comporta cada modelo dependiendo del número de estados ocultos que se proponen (2, 3, 4 y 5 estados, véase columna EO de la tabla 4.7).

**Tabla 4.7:** Resultados de las pruebas realizadas para determinar el vector de características aplicando WD con tratamiento de la imagen térmica.

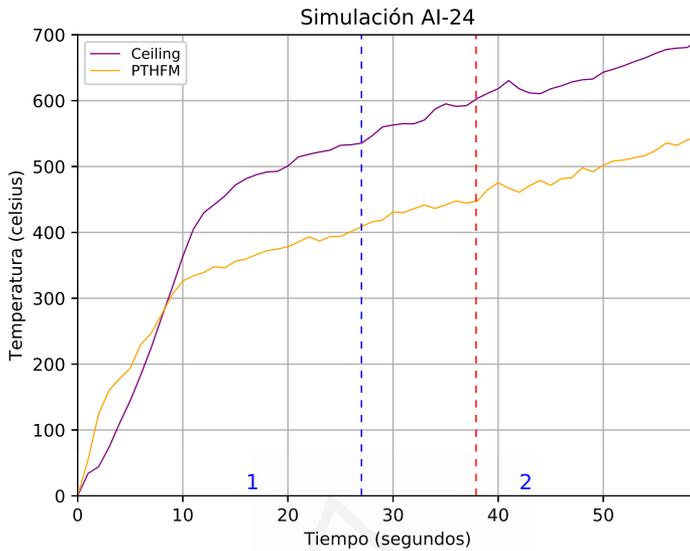
Nº	Sim	EO	ROC	Vector	AUC
1	AI-24	2	Frame	WD	0.85
2	AI-24	3	Frame	WD	0.77
3	AI-24	4	Frame	WD	0.78
4	AI-24	5	Frame	WD	0.69
5	AI-25	2	Frame	WD	0.68
6	AI-25	3	Frame	WD	0.68
7	AI-25	4	Frame	WD	0.68
8	AI-25	5	Frame	WD	0.68
9	AI-41	2	Frame	WD	0.73
10	AI-41	3	Frame	WD	0.64
11	AI-41	4	Frame	WD	0.64
12	AI-41	5	Frame	WD	0.57

La tabla 4.7 revela una variación importante del valor del área bajo la curva dependiendo de la simulación utilizada para entrenar el clasificador. Los resultados obtenidos son comparados con los tiempos de los datos observados de la tabla 4.2.3, obteniéndose resultados interesantes para los modelos creados a partir de la simulación AI-24 con 2 y 3 estados cuyos resultados se presentan en las figuras 4.12, 4.13, 4.14, 4.15, 4.16 y 4.17.

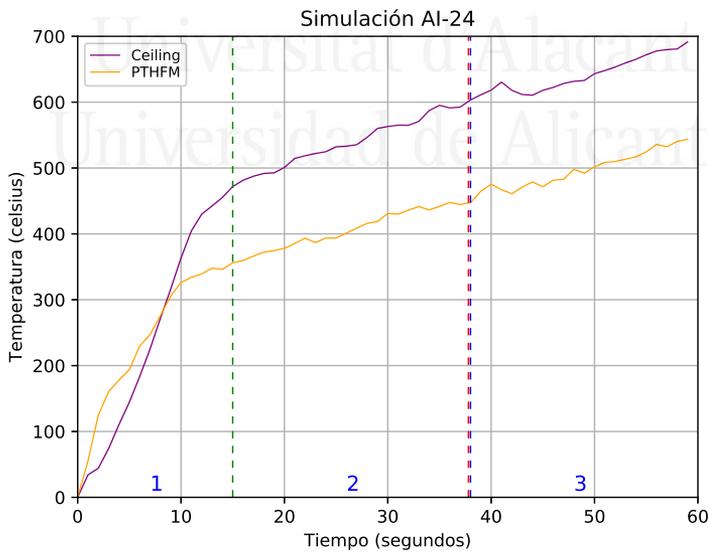
Los datos obtenidos de la aplicación del modelo creado a partir de la simulación AI-24 con dos estados (ver figuras 4.12, 4.14 y 4.16, la línea discontinua azul muestra la predicción del modelo) muestran falta de precisión al predecir el instante exacto de la ocurrencia del *flashover* de

acuerdo con los datos de los sensores (línea roja discontinua vertical). No obstante, se puede observar que en todos los casos el valor de predicción del modelo se anticipa a la predicción observada, marcando el inicio de una situación comprometida ( $550^{\circ}\text{C}$  en el techo y  $400^{\circ}\text{C}$  para el sensor PTHFM). Esto puede ser interpretado como la primera condición para que se produzca el *flashover* (ver sección 2.6), la cual requería una temperatura en el techo medida en el centro del recinto  $\geq 550^{\circ}\text{C}$ . Por lo tanto, podemos decir que el modelo predice correctamente este punto. También se pone de manifiesto que la separación entre estos dos valores está inversamente relacionada con la tasa de liberación de calor del incendio, en vista de que, a mayor pendiente de la curva de los sensores, para un intervalo de tiempo determinado, la separación entre estas es menor. De manera que sería posible determinar el tiempo restante desde la predicción realizada hasta la aparición de un posible fenómeno *flashover* comparando los valores de un intervalo determinado.

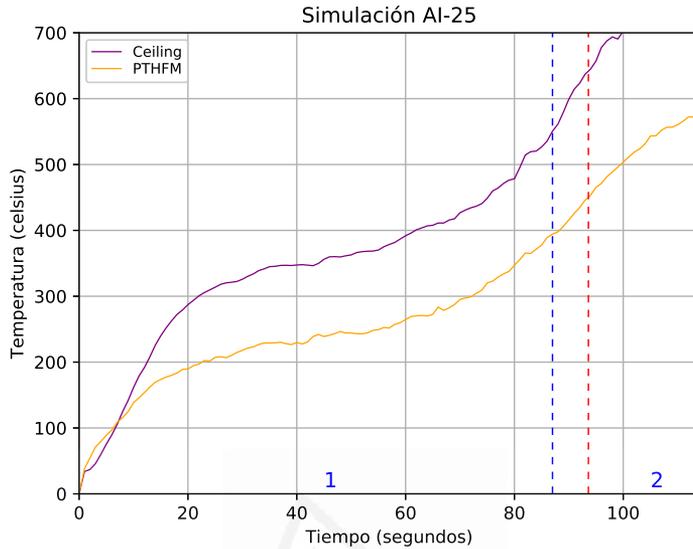
Los resultados de aplicar el modelo de 3 estados ocultos sobre las simulaciones propuestas (ver figuras 4.13, 4.15 y 4.17) muestran que la línea discontinua azul, que separa los estados 2 y 3 en las simulaciones AI-24 y AI-25, coincide con los valores de ocurrencia del *flashover*, línea roja discontinua, según los datos observables, si bien, en la simulación AI-41 estas aparecen unos segundos desplazadas. Esto ocurre, como ya se explicó en el capítulo 3, debido a una estabilización de la curva de incendio y como consecuencia al parecido de las imágenes que se están analizando. En este caso la línea vertical discontinua de color verde marca la transición del estado 1 a 2, presenta como en el modelo de 2 estados, el inicio de un punto crítico que puede ser usado para predecir el fenómeno del *flashover* con antelación. La separación entre las dos líneas, verde y azul, va a depender al igual que en el caso anterior, de la tasa de liberación de calor, por lo que este punto se presenta como un buen indicador para la predicción del *flashover*.



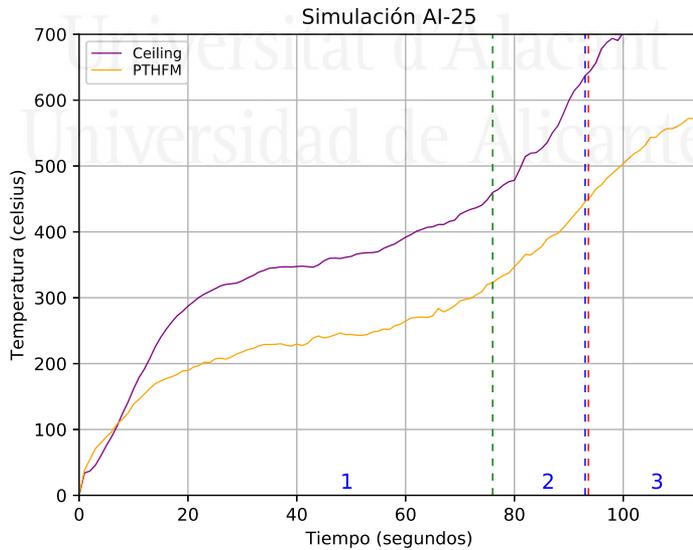
**Figura 4.12:** HMM para 2 estados en la simulación AI-24. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.



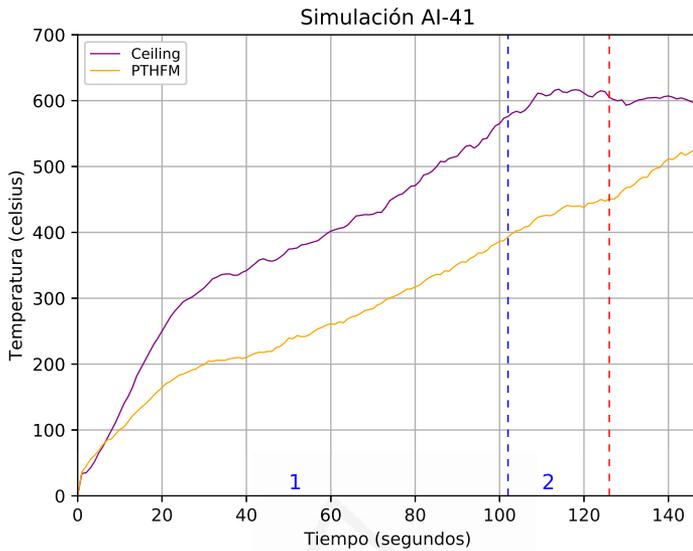
**Figura 4.13:** HMM para 3 estados en la simulación AI-24. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto.



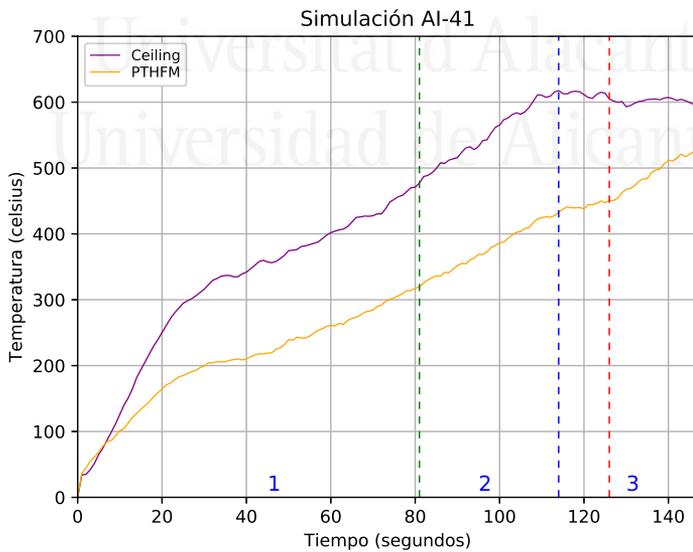
**Figura 4.14:** HMM para 2 estados en la simulación AI-25. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.



**Figura 4.15:** HMM para 3 estados en la simulación AI-25. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto.



**Figura 4.16:** HMM para 2 estados en la simulación AI-41. La línea vertical roja corresponde a la predicción según los datos observados. La línea vertical azul divide la curva de incendio en los 2 estados según el modelo propuesto.



**Figura 4.17:** HMM para 3 estados en la simulación AI-41. La línea vertical roja corresponde a la predicción según los datos observados. Las líneas verticales verde y azul dividen la curva de incendio en 3 estados según modelo propuesto.

A continuación, se muestran las matrices de confusión y los valores de TPR, TNR, PPV, NPV y ACC, resultantes de la aplicación de los HMM de 2 y 3 estados ocultos, obtenidos a partir de la simulación AI-24, sobre las 64 simulaciones restantes. Este análisis sirve para comprobar cómo se están comportando los modelos seleccionados a la hora de clasificar las simulaciones en las que se ha producido el *flashover* y las que no. Los valores que obtienen de ACC (ver tabla 4.9) son similares a los valores del AUC reflejados en la tabla 4.7 para la simulación AI-24 en el caso de 2 y 3 estados, siendo menor el de 2 estados.

		Observación	
		Positivo	Negativo
Predicción	Positivo	41	14
	Negativo	0	9

**Tabla 4.8:** Matriz de confusión para el modelo de 2 estados ocultos obtenida a partir de aplicar el modelo sobre las 64 simulaciones restantes.

		Observación	
		Positivo	Negativo
Predicción	Positivo	39	14
	Negativo	2	9

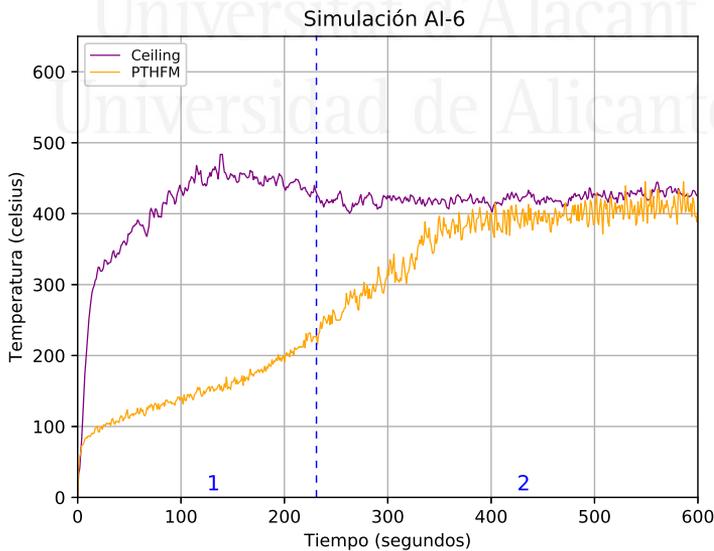
**Tabla 4.9:** Matriz de confusión para el modelo de 3 estados obtenida a partir de aplicar el modelo sobre las 64 simulaciones restantes.

**Tabla 4.10:** Sensibilidad, especificidad, precisión, valores predictivos negativos y exactitud para los modelos estudiados de 2 y 3 estados a partir de la simulación AI-24.

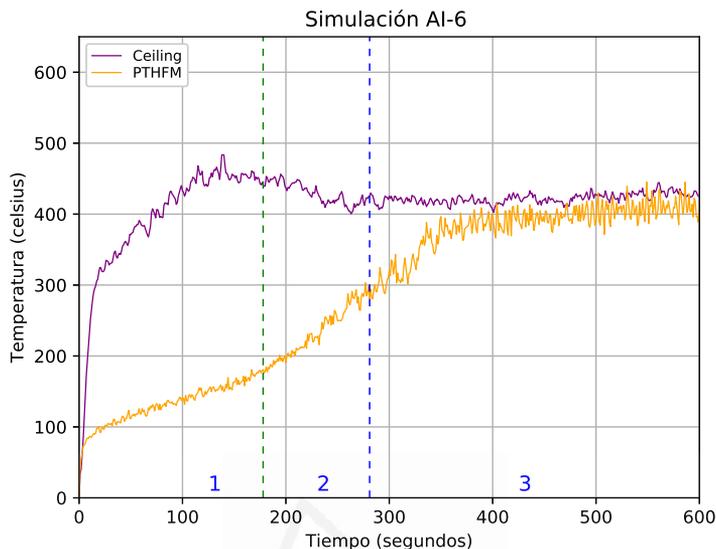
	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
HMM 2 estados	100	39.13	74.54	100	78.12
HMM 3 estados	95.12	39.13	73.58	81.81	75

Del análisis de las matrices de confusión cabe resaltar el elevado número de falsos positivos. De las 64 simulaciones 14 se predicen como falsos positivos debido a que el modelo ha encontrado en la secuencia los estados ocultos correspondientes, pero según los sensores y los parámetros que se han considerado para la ocurrencia de este fenómeno, este no tiene lugar.

El análisis de estas simulaciones desvela que se producen ciertas condiciones que se consideran muy interesantes y pueden desencadenar el *flashover*. En las figuras 4.18 y 4.19 se muestra el registro de los sensores de techo y en el suelo de la simulación AI-6 (FP) junto con los estados ocultos detectados por los modelos de Markov. A pesar de que el sensor de techo registra valores de temperatura por debajo de los  $500^{\circ}\text{C}$ , la temperatura correspondiente al sensor PTHFM alcanza valores muy próximos a la segunda condición de *flashover* ( $454^{\circ}\text{C}$ ). Esto sugiere que los materiales a nivel del suelo estarían muy cerca de la radiación crítica ( $20\text{ kW/m}^2$ ) y por tanto estaríamos ante un escenario muy peligroso. Por este motivo, los falsos positivos tienen que ser objeto de un estudio más profundo para determinar cómo se comporta el modelo de predicción en estos casos.



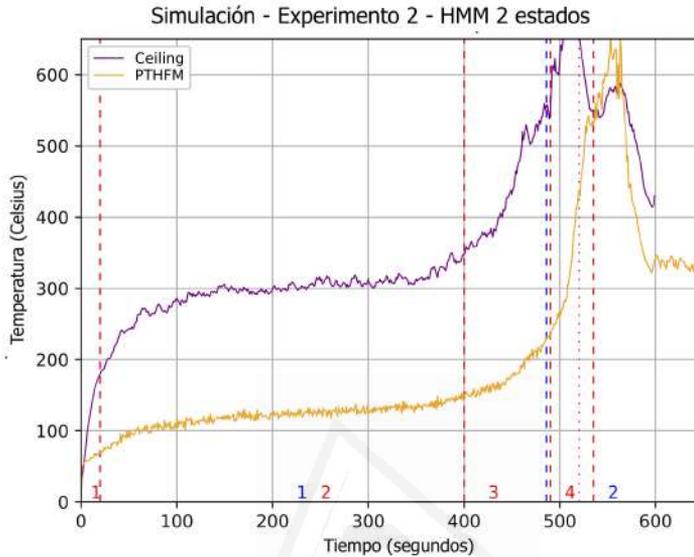
**Figura 4.18:** HMM para 2 estados ocultos en la simulación AI-6. La línea vertical azul divide la curva de fuego en los estados ocultos.



**Figura 4.19:** HMM para 3 estados ocultos en la simulación AI-6. Las líneas verticales verde y azul dividen la curva de fuego en los estados ocultos.

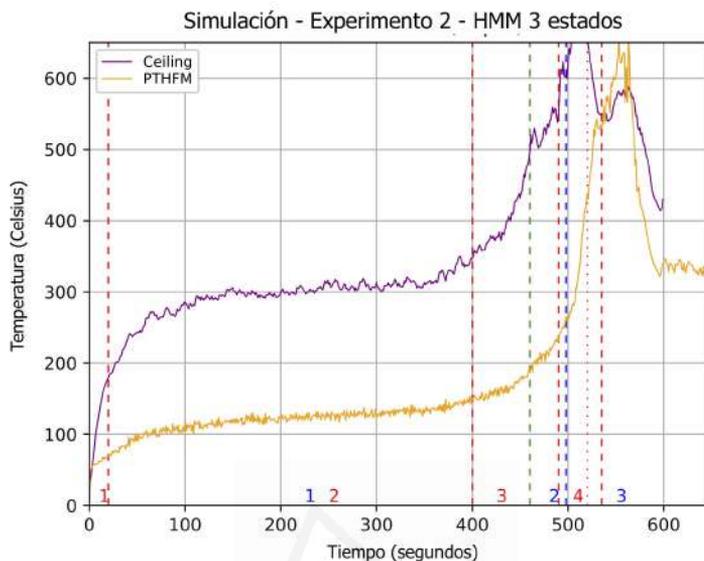
En las figuras [4.20](#) y [4.21](#), se muestra la aplicación de los modelos ocultos de Markov sobre una simulación utilizada en el capítulo [3](#). Esta simulación tiene una duración muy superior a la utilizada para entrenar el modelo, lo que hace interesante su estudio antes de la aplicación sobre el caso real. Los números en rojo representan los estados en los que se dividió la curva de fuego inicialmente según la apreciación de los datos de los sensores. En este caso el cambio de un estado a otro viene determinado por las líneas verticales discontinuas rojas. Los números en azul representan los estados ocultos de Markov identificando la transición entre estados con una línea vertical discontinua azul (modelo de 2 estados) o verde y azul (modelo de 3 estados). Los resultados obtenidos de aplicar los modelos de Markov a esta simulación coinciden con los datos presentados para las simulaciones con un menor tiempo de proceso. Para el modelo con dos estados el valor predicho coincide con la primera condición para que se dé el *flashover* en cuanto a la temperatura (ver figura [4.20](#)). El modelo de 3 estados también concuerda con los datos anteriores, a consecuencia de que la curva de fuego presenta una estabilización a partir de ese punto y las

imágenes son parecidas.



**Figura 4.20:** HMM para 2 estados ocultos en la simulación del experimento 2 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo.

La transición entre los estados 1 y 2 (línea verde) también está en consonancia con todo lo expuesto sobre el modelo de 3 estados ocultos. Estos datos también nos sirven para confirmar que la separación entre las línea verde y azul dependen de la tasa de liberación de calor, debido a que si comparamos los datos de la simulación AI-41 (ver figura 4.17) con los datos de la simulación 2 para 3 estados (ver figura 4.21) el incremento de la temperatura de los sensores es el mismo para un intervalo de tiempo de unos 30 segundos en ambas simulaciones, lo que quiere decir que en ese intervalo la tasa de liberación de calor es la misma. Sin embargo, la simulación AI-41 presenta mayores temperaturas del PTHFM en la intersección con la línea verde debido a una mayor tasa de liberación de calor en intervalos anteriores. Teniendo en cuenta la relación entre dos puntos de la curva de fuego y la tasa de liberación de calor, es posible establecer una relación entre estos y la distancia Wasserstein calculada, como se comentó en el capítulo 3. En relación a este punto, se propone una ecuación (ver ecuación 4.8)



**Figura 4.21:** HMM para 3 estados ocultos en la simulación del experimento 2 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo.

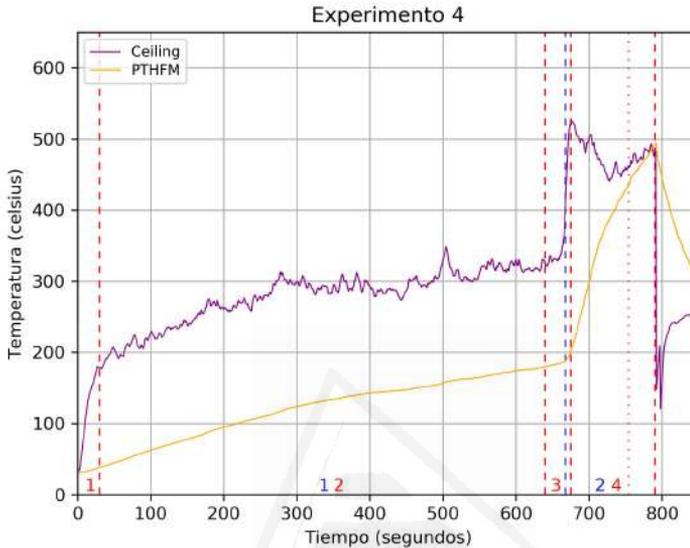
para predecir el tiempo restante (de manera orientativa) hasta el punto de interés a partir de los datos de la simulación de referencia, que en este caso se corresponde con la simulación AI-24.

$$t_i = \frac{WD_{ref} \cdot t_{obs}}{WD_{obs}} \quad (4.8)$$

Donde  $t_i$  es el tiempo calculado hasta el punto de interés,  $WD_{obs}$  y  $t_{obs}$  son la distancia Wasserstein y el tiempo entre las dos imágenes de la observación correspondientes para realizar el cálculo y  $WD_{ref}$  es la distancia Wasserstein correspondiente al punto de interés en la simulación de referencia.

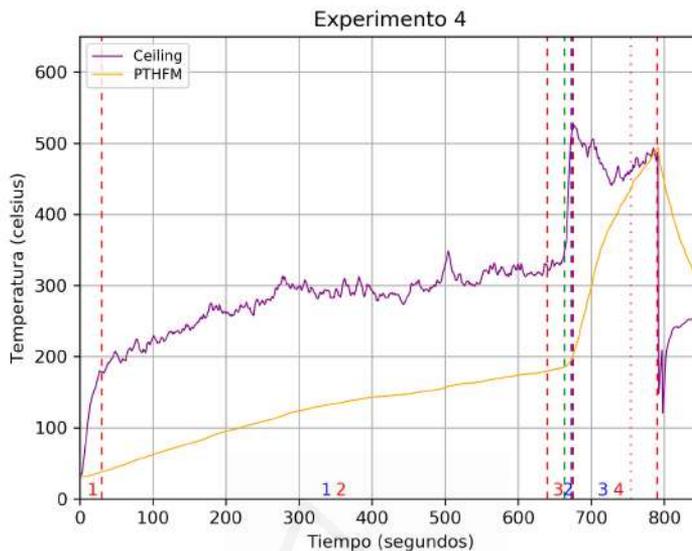
En las figuras 4.22 y 4.23 se muestran los resultados de la aplicación de los modelos de 2 y 3 estados sobre las imágenes obtenidas de la experimentación real. Para este caso se puede observar que en el segundo 665 se produce un fuerte incremento de la tasa de calor liberado, lo que provoca un aumento de temperatura en el interior del compartimento. Este hecho

se constata en la fuerte pendiente que presenta el sensor situado en el techo del compartimento, casi vertical.



**Figura 4.22:** HMM para 2 estados ocultos en el experimento 4 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y las azules en los estados ocultos según el modelo.

El modelo de 2 estados predice el cambio de estado a los 668 segundos (ver figura 4.22) dejando un margen amplio hasta que se produce el *flashover* según los datos de los sensores. En el caso del modelo para 3 estados (ver figura 4.23), se puede apreciar que apenas hay separación entre las líneas que delimitan el estado 2. Estaríamos ante una situación crítica en la que apenas disponemos del margen de seguridad que ofrece el estado 2 en el modelo de 3 estados, prediciendo el final del estado 2 en el segundo 674. En el caso de este modelo, si se aplica la ecuación propuesta al inicio del estado 2 se puede observar que, debido al cambio brusco en la dinámica del incendio (pendiente elevada en los sensores) el  $t_i$  sería de un 1 segundo. Esto se debe a la elevada tasa de liberación de calor del experimento 4 en este punto. Si se comparan los datos de la simulación AI-24 con con los datos del experimento 4, ambos modelos (2 y 3 estados) predicen correctamente la situación, produciendo el cambio de estado para una distancia wassers-



**Figura 4.23:** HMM para 3 estados ocultos en el experimento 4 (ver figura 3.22). Las líneas verticales rojas dividen la curva de fuego en los estados observados y la verde y azul en los estados ocultos según el modelo.

tein e intensidad de radiación máxima idéntica a los datos de la simulación de referencia. Esto quiere decir que las imágenes en las que se produce el cambio de estado son similares. Sin embargo, en este caso, la segunda condición de *flashover* (temperatura en PTHFM  $\geq 454^{\circ}C$ ) no coincide con la primera condición como en la simulación AI-24. Esto se debe a que la alta tasa de liberación de calor produce cambios en la temperatura de la parte superior del recinto que tardan un tiempo en trasladarse a la parte inferior, donde está situado el PTHFM.

Los datos del experimento real se han analizado también con la desviación típica. La aplicación de los modelos de Markov de 2 y 3 estados utilizando este tipo de vector de características no identifican ningún estado oculto en la secuencia del experimento real. Esto se debe a que, como se explicó en el capítulo 3, las imágenes obtenidas con la cámara de visión térmica no son iguales a las de simulaciones, puesto que varía la distancia al objetivo y el encuadre. Esto hace que las desviaciones típicas calculadas

en la imagen real no estén dentro del mismo rango que en la secuencia utilizada para entrenar el modelo, por lo que la predicción falla. Esto último descarta el uso de la desviación típica para la predicción del *flashover* según el modelo propuesto siendo el único vector de características que funciona correctamente el formado por la distancia Wasserstein.

## 4.5. Conclusiones

En este capítulo se han estudiado los modelos ocultos de Markov para la predicción del *flashover*. De los resultados de los modelos propuestos se pueden sacar las siguientes conclusiones.

Se han propuesto cuatro vectores de características distintos para analizar su comportamiento. A partir de los resultados obtenidos es posible afirmar que la distancia Wasserstein y la desviación típica ofrecen mejores resultados que la suma de valores de las columnas o de las filas de la imagen térmica. Aunque la desviación típica presenta valores similares en cuanto a predicción que la distancia Wasserstein, esto no ocurre así cuando se utiliza sobre el caso real. Esto se debe a que como se explicó en el capítulo 3, las imágenes en los experimentos reales son tomadas a una distancia y encuadre diferente a las de las simulaciones. Como resultado, el clasificador creado a partir de la desviación típica no predice ningún estado oculto en la experimentación real, siendo el único vector de características que funciona correctamente el formado por la distancia Wasserstein.

En cuanto al tipo de secuencia para el caso que nos ocupa, queda patente que el clasificador es altamente sensible a la secuencia con el que se entrena, no teniendo tanto peso la cantidad de secuencias. La predicción del punto en el que se produce el incendio totalmente desarrollado según los sensores, depende de la evolución del incendio, observándose problemas en los casos en los que se produce una estabilización de este (ver figuras 4.16, 4.17, 4.20, 4.21, 4.22 y 4.23), posiblemente debido al parecido del área de estudio y a las probabilidades de emisión del modelo, pero hacen falta más casos de estudio para estudiar a fondo este punto.

Sin embargo, en los casos en los que en la evolución la temperatura en el interior del recinto aumenta de forma continua, la predicción es excelente. Los modelos propuestos clasifican con éxito las situaciones de *flashover* y se propone una ecuación para predecir el tiempo hasta el *flashover* (modelo 2) o el tiempo del estado 2 y el flashover (en el caso del modelo 3), dependiendo la precisión del resultado de la evolución del incendio. La implementación del algoritmo de avance-retroceso (forward-backward algorithm) puede ayudar a calcular de una forma más precisa el tiempo de predicción para que se produzca una situación comprometida, pero es necesario un estudio más profundo de las secuencias para una aplicación correcta.

El análisis de las matrices de confusión de las simulaciones revela un alto número de falsos positivos. Después del estudio de los casos se llega a la conclusión de que los modelos predicen situaciones potencialmente peligrosas en la mayoría de ellos, por este motivo estos tienen que estudiarse más a fondo para mejorar la precisión de los modelos y redefinir las potenciales situaciones en las que el *flashover* puede ocurrir.

De todo lo anterior se concluye que es posible predecir el fenómeno *flashover* utilizando los modelos ocultos de Markov y la distancia Wasserstein con un alto grado de precisión.



Universitat d'Alacant  
Universidad de Alicante

# Conclusiones

---

En este capítulo se presentan las principales conclusiones extraídas del trabajo realizado. El capítulo está organizado de la siguiente forma: el apartado 5.1 muestra las conclusiones generales como resultado del trabajo de investigación; la sección 5.2 lista las principales publicaciones realizadas en revistas y congresos en el tema de investigación; finalmente, en la sección 5.3 se presentan posibles opciones de trabajos futuros.

## 5.1. Conclusiones generales

Las conclusiones que se derivan de este trabajo de investigación que se presenta enlazan entre sí los temas tratados para desarrollar el método propuesto para la predicción del *flashover*, y son las que se exponen a continuación.

A la pregunta que se presentó en el capítulo 1.1 y que da lugar al origen de esta tesis:

*¿sería posible desarrollar un método para ayudar a predecir este tipo de situaciones utilizando cámaras de visión térmica?*

En esta tesis se demuestra que, con el método desarrollado para predecir el *flashover* en tiempo real con cámaras de visión térmica, es posible saber

cuándo se va a producir este fenómeno. Este método permite al personal que está interviniendo en el interior del recinto, centrarse en las tareas de extinción, búsqueda o rescate, aumentando su efectividad. Por otra parte, el método propuesto elimina el error humano, ya que la predicción se hace de una manera automática aplicando técnicas de inteligencia artificial. A esto hay que añadir que se trata de un método versátil y flexible ya que puede adaptarse a diferentes tipos de cámaras de imagen térmica y montarse en diferentes dispositivos, como cámaras manuales o drones. Los valores de precisión del método propuesto utilizando los Modelos Ocultos de Markov con 2 y 3 estados se presentan en la tabla 5.1. Con este modelo es posible predecir situaciones de *flashover* y estimar el tiempo restante para que este se produzca.

**Tabla 5.1:** Valores de precisión para método propuesto con HMM y tres estados

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
HMM 2 estados	100	39.13	74.54	100	78.12
HMM 3 estados	95.12	39.13	73.58	81.81	75

Sin embargo, no es posible hacer esta afirmación en el caso del *backdraft*, ya que el trabajo de investigación se ha centrado únicamente en el fenómeno *flashover* como consecuencia de no haber detectado suficiente conocimiento, hasta donde se ha investigado sobre este fenómeno, en la revisión del estado del arte (ver capítulo 2).

El objetivo fundamental de esta tesis era proponer un método para la predicción del *flashover* y *backdraft*, en tiempo real, usando cámaras de imagen térmica. Se trata de un punto clave para ayudar a los servicios de emergencias a prevenir este tipo de fenómenos, que se dan en los incendios confinados. Para alcanzar este objetivo, se fijaron varios objetivos específicos, cuyos resultados se exponen a continuación.

- **Evaluar el estado de la cuestión:** en el capítulo 2 se llevó a cabo una revisión del estado del arte, para finalizar se realizó una discusión de los resultados y se expusieron unas conclusiones (ver apartado

2.6). A continuación, se muestran los resultados derivados de este estudio.

- El principal resultado de este análisis es que, de los dos fenómenos que se proponen en un principio para realizar la predicción, el *backdraft*, hasta donde se ha investigado, no presenta suficiente conocimiento sobre las causas que lo originan, por esta razón el trabajo de investigación se ha centrado en el método para la predicción del *flashover*.
  - Como consecuencia del análisis del modelado y simulación, se elige el software de simulación de fluidos computacional FDS para llevar a cabo la investigación.
  - Los trabajos revisados señalan que, la temperatura a nivel del techo y la radiación a nivel del suelo, pueden utilizarse para conocer cuándo se produce el *flashover*. Estos valores se utilizan para el diseño de las simulaciones y en la etapa de validación del conjunto de datos sintéticos, para poder establecer un criterio para dividir la curva de fuego en las diferentes etapas (ver apartado 3.3.1), y para realizar la predicción (ver apartado 4).
  - La revisión del estado del arte señala que no hay trabajos relacionados que aborden el problema de predicción de este tipo de fenómenos con cámaras de visión térmica. Por lo tanto, el presente trabajo se puede considerar pionero en la predicción del flashover con TC utilizando técnicas de inteligencia artificial.
- **Desarrollar una metodología para generar un conjunto de datos de imágenes sintéticas:** en el capítulo 3 se desarrolla una metodología para generar imágenes sintéticas a partir de software CFD con el propósito de suplir la carencia de datos reales de este tipo de situaciones. Para su desarrollo se tiene en cuenta LES, el modelo de radiación de banda estrecha, la ecuación de transferencia de

radiación térmica y las variables de calibrado de la TC. Este último punto hace posible la aplicación de esta metodología con cualquier tipo de TC. El método propuesto para generar un conjunto de datos sintéticos a partir de simulaciones demuestra que es posible generar un conjunto de datos con imágenes que sustituyen a las que proporciona una determinada cámara de imagen térmica. De esta manera pueden generarse los datos sintéticos necesarios para poder aplicar técnicas de inteligencia artificial con el fin de crear modelos de predicción, resolviendo así el problema de la casi inexistencia de datos reales del *flashover*. Como resultado se han podido generar conjuntos de datos sintéticos compuesto de imágenes transformadas procedentes de las simulaciones. Los conjuntos de datos sintéticos generados, obtenidos mediante el método propuesto, se utilizan tanto en la etapa de validación como para el entrenamiento del modelo de predicción.

- **Desarrollar una metodología de validación y clasificación cuantitativa:** para poder validar y clasificar el conjunto de datos sintéticos cuantitativamente se desarrolla en el capítulo 3 una metodología con tal fin. El método propuesto es capaz de validar y clasificar las imágenes que forman un conjunto de datos sintéticos en las diferentes etapas de la curva de fuego. Además, en los gráficos de convolución WD es posible apreciar cómo se comporta la simulación respecto a la experimentación por lo que se presenta como una herramienta válida de comparación. Debido a esto, este método sería posible aplicarlo también en investigación de incendios (utilizando la entrada ROI, ver figuras 3.20 y 3.24), para comprobar si la simulación se aproxima al incendio real, del que se han obtenido previamente las imágenes térmicas del humo saliendo por el hueco de ventilación. Como resultado los datos generados con el método comentado en el punto anterior son validados y clasificados en diferentes etapas de la curva de fuego. El método presentado da solución a la carencia de datos reales de este tipo de fenómenos para poder utilizar el conjunto de datos sintéticos con fines predictivos.
- **Predecir el *flashover* en tiempo real:** en el capítulo 4, se ha

propuesto un modelo de predicción utilizando los modelos ocultos de Markov en conjunto con la distancia Wasserstein para predecir los estados en los que queda dividida la curva de fuego (ver apartado 3.3). Como resultado, la utilización de esta técnica en el método propuesto permite clasificar la imagen real obtenida en un instante determinado dentro de un estado, pudiendo identificar cuando la imagen pertenece al estado del *flashover*. El uso de los modelos ocultos de Markov se presenta como una técnica novedosa para la predicción del *flashover* utilizando este método. La aplicación de este modelo consigue identificar los estados en los que se divide la curva de fuego prediciendo con los modelos propuestos la aparición de este fenómeno y se propone una ecuación para calcular el tiempo hasta la condición de *flashover*.

Después de analizar toda la documentación presentada en este documento se puede afirmar que, en el caso del *flashover*, es posible predecir este tipo de situaciones con cámaras de visión térmica haciendo uso del método desarrollado en esta tesis.

## 5.2. Publicaciones y visibilidad

A continuación, se presentan las publicaciones científicas realizadas y las publicaciones que están pendientes de publicación derivadas del presente trabajo:

1. **Review of Modelling and Simulation Methods for Flashover Prediction in Confined Space Fires** [22]. Revista: Applied Sciences-Basel, revisión por pares, factor de impacto 2.474 . En este artículo se lleva a cabo una revisión de las técnicas de modelado, simulación y predicción del fenómeno *flashover*. En esta revisión también se tiene en cuenta el uso de cámaras de visión térmica en la predicción de este tipo de fenómenos.
2. **Fire Science Living Lab for Flashover Prediction** [21]. Revista: Sensors (MDPI Proceedings), 13th International Conference on Ubiquitous Computing and Ambient Intelligence UCAmI 2019, revisión por pares. En este artículo se muestra un resumen sobre el

proceso para desarrollar un sistema de predicción en un *Living Lab* para una de los fenómenos más peligrosos que se pueden encontrar los bomberos en espacios confinados, el *flashover*.

3. **Revisión del modelado y simulación para la predicción de explosiones en incendios de espacios confinados** [20]. International Conference on Research and Advance Technology in Fire Safety, revisión por pares. En este documento se revisan, el modelado, la simulación y la predicción de los diferentes tipos de explosiones que se pueden dar en espacios confinados.
4. **Quantitative model-based imaging of mid-infrared radiation for flashover prediction in confined fires**, Revista: Remote Sensing (en revisión), revisión por pares, factor de impacto 4.509. En este artículo se describen los métodos propuestos para la generación y validación de conjuntos de datos sintéticos con la intención de ser utilizados, en lugar datos reales debido a su carencia, para la predicción del fenómeno *flashover*.
5. **Hidden Markov Models for Flashover Prediction** (en proceso de redacción). Este artículo describe el método propuesto para la predicción del *flashover* en tiempo real utilizando cámaras de visión térmica.

### 5.3. Líneas futuras

Se identifican diferentes líneas de investigación que se derivan del presente estudio. Como continuación natural del trabajo desarrollado en esta tesis, una línea futura inmediata podría ser validar el método propuesto en incendios de tamaño real incluyendo ruido ambiental derivado de objetos que pueda haber en el campo de visión, para estudiar cómo se comporta el clasificador.

Es necesario realizar un mayor número de simulaciones y experimentos reales para profundizar en esta clase de modelos aplicados a la ciencia del

fuego.

El estudio del comportamiento del modelo en el caso de los falsos positivos incrementaría la eficacia del clasificador y podría ayudar a redefinir situaciones comprometidas en esta clase de emergencias. El método propuesto para validar el conjunto de datos sintéticos puede ayudar a encontrar patrones ocultos en las imágenes que incrementen la seguridad en este tipo de intervenciones.

Otra línea necesaria es estudiar esta clase de modelos en incendios en los que se dispongan de varias aberturas de ventilación, ya que en el método desarrollado únicamente considera recintos confinados con un hueco de ventilación. A esto habría que añadir el estudio de la predicción del *flashover* en recintos más complejos, que dispongan de varias estancias.

En cuanto a la predicción, sería interesante aplicar otros modelos de inteligencia artificial para comparar su efectividad con la técnica utilizada, como por ejemplo las redes neuronales recurrentes, deep learning, SVM, decision trees e incluso establecer métodos híbridos con lógica difusa para dividir las fases de las imágenes.

Es necesario realizar más estudios en la línea de los HMM para estudiar la influencia de diferentes secuencias, así como la imagen base sobre la que se realiza la comparación de la distancia Wassertein, con el fin de obtener modelos más precisos.



Universitat d'Alacant  
Universidad de Alicante

# Apéndices



Universitat d'Alacant  
Universidad de Alicante



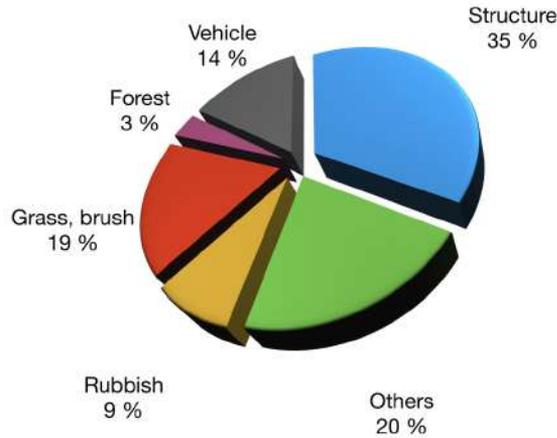
# Summary and conclusions

---

## A.1. Summary

### A.1.1. Context and motivation

Enclosure or confined fires are situations that firefighters are used to handling. The consequences of this type of emergency can involve people and structures. A confined fire is one that takes place inside structures such as blocks of houses, garages, single-family homes and commercial establishments. The last International Association of Fire and Rescue Services (CTIF) study [8] suggests that 35% of fires (see figure A.1) located in several cities around the world are structure fires. These kinds of emergencies caused civilian (non-fire service) deaths, civilian fire injuries and property damage. Currently, the reported data about this phenomenon in Europe is scarce. This is because there is not a common database that involves all European countries and most fire services do not document such situations. An example of this is the study carried out by the European Fire Safety Alliance (EFSA), which only involves nine countries. Table A.1 shows an overview of the research [58] results carried out for EFSA related to residential fires.



**Figure A.1:** Distribution of fires by types. International Association of Fire and Rescue Services by Center of Fire Statistics of CTIF 2018 [8].

**Table A.1:** Population, fatalities per capita per year and percentage of fatal fires in selected European countries [58].

Country	Population (Million)	Fatalities Per Year (per ha)	Per Capita (per 100000)	% Fatal Fires (Related to All Residential Fires)
Belgium (2014–2015)	11.4	0.6		0.5%
Denmark (2011–2012)	5.8	1.1		1.2%
Estonia (2013–2017)	1.3	3.7		4.6%
Finland (2011–2012)	5.53	1.4		
Netherlands (2011–2014)	17	0.2		0.6%
Norway (2016–2017)	5.3	0.5		1.3%
Poland (2011–2012)	38	1.3		
Sweden (2011–2013)	10	1.1		1.2%
UK (2014)	66	0.6		
<b>Total</b>	160.3			
<b>Total Europe</b>	742.9			

To compare these results with data from another continent the reader can refer to the National Fire Protection Association (NFPA [4]) statistics. According to NFPA, during the five-year period between 2010–2014, USA fire departments responded to an estimated annual average of 358 300 home structure fires. These kinds of emergencies caused an annual average of 2 520 civilian (non-fire service) deaths, 12 720 civilian fire injuries, and US\$ 6.7 billion in direct property damage. On average, seven people died each day in the US in home fires during this

period. Currently it is very difficult to obtain accurate data to evaluate confined space fires in Europe, because there is no database available for this dangerous emergency type. Furthermore, there is no data available on how this type of enclosure fire affects emergency teams, materials or victims.

In order to get some idea of the risk for people involved in these situations, Table 1.2 provides a more detailed breakdown of losses by occupancy in two types of buildings, family homes and buildings. 70% reported home structure fires and 84% of the fatal home fire injuries occurred in one- or two-bedroom family homes, including manufactured homes.

**Table A.2:** Reported home structure fires by property use (NFPA [4]), 2010–2014 annual averages.

Property Use	Fires	Civilian Deaths	Civilian Injuries	Direct Property Damage (in Millions)
One- or two-family homes, including manufactured home <sup>1</sup>	250 500 (70%)	2 100 (84%)	8 440 (66%)	\$5 438 (81%)
Other multi-family housing <sup>2</sup>	107 800 (30%)	410 (16%)	4 280 (34%)	\$1 271 (19%)
Total	358 300 (100%)	2 520 (100%)	12 720 (100%)	6 710\$ (100%)

<sup>1</sup> One or more bedrooms are considered; <sup>2</sup> dwellings, duplexes, manufactured homes (also called mobile homes), apartments, terraced-houses and townhouses. Other residential properties, such as hotels and motels, dormitories, barracks, rooming and boarding homes and the like are not included. One or more bedrooms are considered.

To understand the combustion process in the enclosure it is necessary to introduce the reader to fuel-controlled (FC) and ventilation-controlled (VC) concepts. A compartment fire [4] is one that takes place inside an enclosed area, such as a house, in which two circumstances can occur:

- The enclosure is ventilated, the oxygen consumption is less than the available amount.
- The room is under-ventilated (lack of inlet air or lack of an outlet for the smoke). During the combustion process, oxygen levels in

the enclosure decrease. No open vents or oxygen displacement by combustion gases can be the causes.

If there is sufficient oxygen to consume the fuel pyrolysis gases released, this is known as an FC scenario. Conversely, if there is lack of oxygen to continue the reaction, this is a VC situation. Considering both enclosure situations (ventilated and under-ventilated), once the ignition in a material has occurred, there are several ways in which the situation may evolve. If the fire dies after ignition in a ventilated enclosure, this can be because the energy released is not sufficient to further pyrolysis in the same material or in nearby materials. For that reason the fire can not spread (FC). Alternatively, if the enclosure is under-ventilated, the lack of oxygen in early stages can result in a non-adequate mix with fuel gases impeding the combustion process (VC). Another possibility is when the heat released from the flames is enough to generate new pyrolysis gases from new unburned material and sufficient oxygen is present to maintain the combustion process. Subsequently, fire reaches the growing stage, where fire can spread over the same surface as flames spread or reach other surface materials by radiation. In a ventilated confined space, all fuel can be burned and fire dies or a transition from FC to VC can take place causing the fire to die out due to lack of oxygen. In some cases, the fire can grow to become a fully developed fire after a transition stage known as *flashover*.

*Flashover* phenomenon, or also called generalised sudden combustion, can be defined as a transition phase from growth to fully developed stage (see figure [A.2a](#)). Consequently, all combustible surfaces inside the enclosure, that were not involved in the fire, begin to burn. It occurs due to the radiation received from the smoke layer which can be up to 170 kW/m<sup>2</sup> [\[60\]](#). Once all fuels are involved in the fire the fully developed stage is reached. As a result, firefighters can't stay inside the enclosure under *flashover* conditions, 80 kW/m<sup>2</sup> is the maximum supported radiation by their clothes according to NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting. In Table [A.3](#) different radiation values are shown, and they can be compared to the maximum heat flux for a *post-*

*flashover* case to get an idea of this phenomenon’s power.

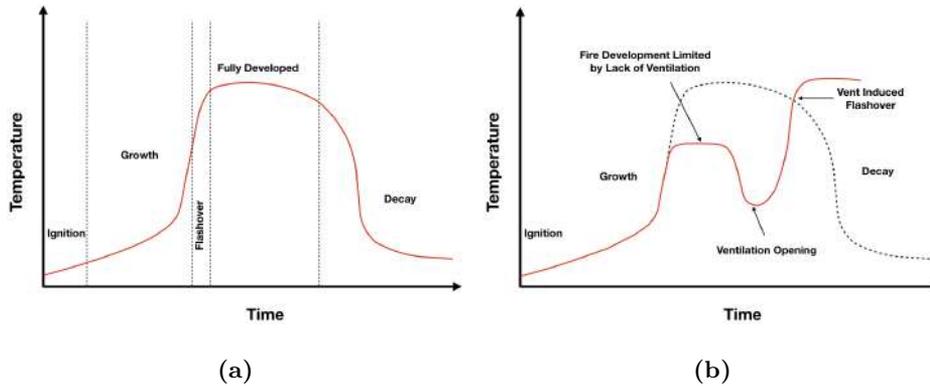
**Table A.3:** Approximate radiant heat flux [60].

Approximate Radiant Heat Flux (kW/m <sup>2</sup> )	Comment or Observed Effect
170	Maximum heat flux as currently measured in a <i>post-flashover</i> fire compartment.
80	Heat flux for protective clothing Thermal Protective Performance (TPP) Test. <sup>1</sup>
52	Fiberboard ignites spontaneously after 5 s. <sup>2</sup>
29	Wood ignites spontaneously after prolonged exposure. <sup>3</sup>
20	Heat flux on a residential family room floor at the beginning of <i>flashover</i> . <sup>4</sup>
16	Human skin experiences sudden pain and blisters after 5-second exposure with second-degree burn injury. <sup>5</sup>
12.5	Wood volatiles ignite with intended exposure <sup>6</sup> and piloted ignition.
10.4	Human skin experiences pain with 3-second exposure and blisters in 9 s with second-degree burn injury. <sup>7,8</sup>
6.4	Human skin experiences pain with a second exposure and blisters in 18 s with second-degree burn injury. <sup>9,10</sup>
4.5	Human skin becomes blistered with a 30-second exposure, causing a second-degree burn injury. <sup>11</sup>
2.5	Common thermal radiation exposure while fire fighting. <sup>12</sup> This energy level may cause burn injuries with prolonged exposure.
1.4	Thermal radiation from the sun. Potential sunburn in 30 min or less. <sup>13</sup>

<sup>1</sup> From NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting; <sup>2</sup> From Lawson, “Fire and the Atomic Bomb.”; <sup>3</sup> From Lawson, “Fire and the Atomic Bomb.”; <sup>4</sup> From Fang and Breese, “Fire Development in Residential Basement Rooms.”; <sup>5</sup> From NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting; <sup>6</sup> From Lawson and Simms, “The Ignition of Wood by Radiation,” pp. 288–292; <sup>7</sup> From NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting; <sup>8</sup> From Lawson, “Fire and the Atomic Bomb.”; <sup>9</sup> From NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting; <sup>10</sup> From Tan, “Flare System Design Simplified,” pp. 172–176; <sup>11</sup> From NFPA 1971, Standard on Protective Ensemble for Structural Fire Fighting; <sup>12</sup> From U.S. Fire Administration, “Minimum Standards on Structural Fire Fighting Protective Clothing and Equipment.”; <sup>13</sup> From Bennett and Myers, Momentum, Heat, and Mass Transfer.

The NFPA [60] also defines *flashover* as the transient phase in the development of an indoor fire in which surfaces exposed to thermal radiation reach their ignition temperature almost simultaneously and the fire spreads rapidly throughout the space available within the enclosure.

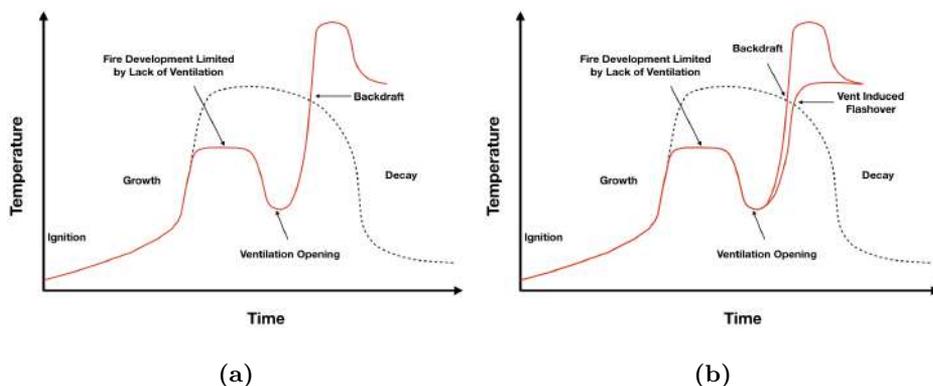
*Flashover* can occur in two different scenarios related to the enclosure configuration and it depends on whether the fire is located inside a structure with constant air supply or not. The first one known as a fuel-limited fire is shown in Figure A.2a. In the growth stage there is enough oxygen to maintain the combustion process. If the amount of fuel involved is sufficient, the energy level necessary for the occurrence of *flashover* can be reached followed by the fully developed phase. Then, as the fuel is burned away, the energy level begins to decay. Once the fully developed phase is



**Figure A.2:** *Flashover* and ventilation induced *flashover* . (a) *Flashover* representation as a transition phase in the fire standard curve before the fully developed fire stage in an enclosure. (b) VIF as a consequence of an infra-ventilated fire.

achieved, in most cases the fuel mass release rate becomes so high that the air supply rate becomes insufficient to consume all released pyrolysis gases (fuel-controlled to ventilation-controlled) [57] and the energy level begins to decay. On the second one (see figure A.2b), classified as under-ventilated situations, *flashover* stage can be reached after a fire dynamics change. It can be produced due to induced ventilation or opening a vent in the structure such as a door or window. Furthermore, due to the high quantity of radiation necessary to reach the *flashover* stage a minimum amount of fuel is necessary to produce it. In addition, the value of the energy generated by indoor fires with a single opening through which the air inlet and gas outflow are channelled can be approximate using the Kawagoe equation [41].

*Backdraft* involves fire limited by ventilation (see figure A.3a) whereby the oxygen availability in the enclosure limits the fire's growth and power. This kind of phenomenon [60] is a deflagration as a consequence of a sudden air supply to a fire in a confined space in which there are incomplete combustion products due to the lack of oxygen. In this type of scenario in confined spaces, the oxygen present in the enclosure can reach minimal values because there is no ventilation opening, placing



**Figure A.3:** Ventilation induced *flashover* (VIF) and comparison between VIF and *backdraft*. (a) *backdraft* representation. (b) Comparison between *backdraft* and VIF.

the fuel-combustion mixture above the flammability range. The fire falls into a latent state. The incomplete combustion that occurs from the decrease of the oxygen due to increased combustion process consumption, causes unburned pyrolysis products into the smoke layer. At this point, a ventilation opening could cause the fuel-combustion mixture to be within the range of flammability. When this flammable mixture meets an ignition source, the mixture is ignited. The flame propagates towards the open vent creating an overpressure. The turbulence will enhance the mixing between fuel and oxygen increasing its flammability. Subsequently as gases ignite outside the room a fireball will take place, typically associated with *backdraft* [27, 46]. Not only *backdraft* phenomenon can occur in under-ventilation conditions in an enclosure but also ventilation induced *flashover* (VIF) can take place. These two phenomena (*backdraft* and VIF) are very much alike but are not the same. VIF can be defined as a continuation of the fire development once a vent is opened. The difference is described as a transient event (*backdraft*) and a step event (*flashover*) by Grimwood et al [28].

Currently, fire services use thermal cameras (TC) in different types of emergencies related with fire and rescue [75]. Furthermore it can provide value real-time information during an enclosure fire. However, the

prediction of this phenomena is not easy and on many occasions it could be a problem for firefighter teams who risk their lives in this situations. In the last 20 years as a firefighter, I had the opportunity to manage several confined fires. It allowed me to know the complexity of these phenomena as well as their dangerousness. Firefighters safety is essential in solving these kind of emergencies successfully. For this reason, the question that motivates this research work is: would it be possible to develop a method to help predict this type of situation using thermal imaging cameras?

### A.1.2. Solution proposal

Taking into account the *backdraft* state of art, additional research is necessary (to the best of my knowledge) to deepen the chemical and physical causes that produce this phenomenon. For this reason, this thesis is focused on proposing a methodology for flashover prediction using AI techniques. The proposed method focuses on the smoke coming out through the ventilation hole, so the prediction is made from the confined space outside using a thermal vision camera (see figure [A.6](#)). This would provide a solution for firefighters decreasing their workload. By discharging firefighters from the task of monitoring the smoke layer allows them to focus on actions such as extinction, search for people or evacuation, increasing the *flashover* forecast effectiveness. The proposed method considers to locate the thermal camera perpendicular to the wall of the ventilation shaft (see figure [A.6](#)) for the following reasons:

- **Avoid personal injury.** Because the thermal radiation coming through the ventilation shaft, with a camera location facing the opening's principal facade, can cause severe damage to firefighters.
- **Avoid focusing on burning material.** On certain occasions, burning fuel can be located through the ventilation hole. This can lead to errors in this phenomenon prediction.

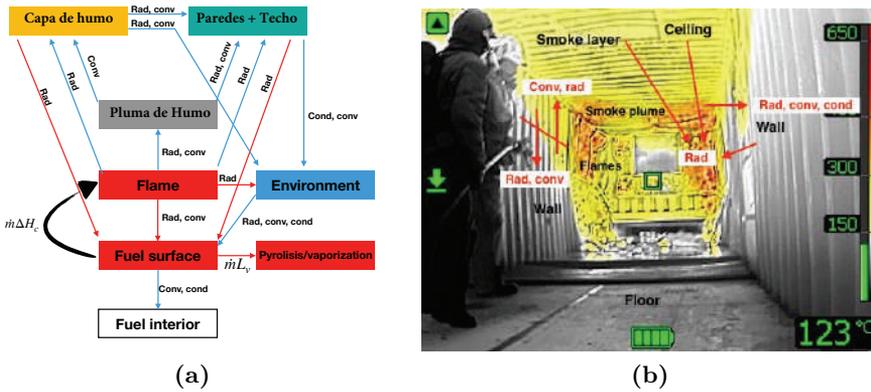
Considering images from real emergencies of such situations are complicated to obtain, I propose a new methodology to generate useful

synthetic image data-sets from CFD software. The image data-sets are expected to support *flashover* forecasting in real time using AI techniques. In addition to that, a methodology to validate and classify the synthetic data-set is proposed in this work. The figure [A.5](#) shows an overview of the two proposed methods to generate and validate the synthetic data-set. Finally, I propose a prediction method using Hidden Markov Models and the synthetic data-sets.

### A.1.3. State of art

The thesis review focuses on certain types of fires in confined spaces where *flashover* and *backdraft* phenomena is likely to occur [\[60\]](#). In these emergencies, firefighters try to anticipate this situation by reading enclosure fire dynamics (e.g., see figure [A.4](#)) tracks. Sometimes this is not possible due to the rapid response multitasking nature of the emergency and the corresponding stress that these situations generate for the firefighter. Attempting a prevention of the *flashover* described in this research, the firefighter handling the TC tries typically to monitor the hot gas layer's temperature to detect changes in the environment. However, this method is not very accurate because *flashover* depends on multiple elements such as compartment configuration, fuel and ventilation, and most importantly, the human factor. Another reason is that temperature acquisition with a TC does not work in the same way when a smoke layer is present. This is because the temperature shown by the camera is the reflection temperature and not the inside temperature of the smoke layer. For instance, carbon particles or water vapour can reflect the visible light interfering in the image acquisition process. On the other hand, due to the long wave of infrared light it is not easily reflected by smoke layer particles.

Given the previous discussion, it is worthwhile mentioning the potential for using AI to predict this phenomenon. For this reason, in this research have been reviewed work which has applied AI in similar situations. Through AI techniques, which focus on the study of intelligent agents, a device can take actions that maximise the chances of successfully



**Figure A.4:** Enclosure effects on heat transfer in a fire container. (a) Schematic overview: Blue arrows indicate heat transfer, which is not used in the fire process; “rad” refers to radiation, “cond” refers to conduction and “conv” refers to convection. The curved arrow refers to the mass flow rate of combustible gases [57]. (b) Thermal image of enclosure effects in a fire container during a firefighting training at San Vicente Fire Station, Alicante, Spain.

completing a task based on environment perception. Nowadays artificial intelligence techniques, such as flame detection [35, 36], fire spread [39], fire and smoke classification [42], *flashover* occurrence [47, 49], thermal interface location in a single compartment fire [50] or temperature and velocity profiles [86] among others, have been proven to predict certain fire-related situations. Different approaches have been used to research fire prediction. The most commonly adopted approach is artificial neural networks (ANN). ANN are computing systems usually used to find complex relationships between a source (input) and a target (output). Furthermore, research about fire science including this technology can be found. For example, in image recognition, they might learn to identify fire images by analysing example images and using the results to detect fire in other images [32]. Related to image data-set, convolutional neural networks (CNN) seem to be more effective in finding highly accuracy patterns. It is noteworthy to mention that it is challenging to find a useful data-set of real *flashover* emergencies. To address this interesting point, this study reviews research that used synthetic data obtained from simulations.

Novel techniques used for modelling, simulation and prediction of *flashover* and *backdraft* phenomena in confined fires have been reviewed in this work, identifying future opportunities and challenges. As far as modelling and simulation are concerned, the most recent *flashover* and *backdraft* studies have been reviewed. Although the articles analysed describe a deep level of knowledge about these phenomena some issues require further exploration, especially in the context of *backdraft* phenomenon.

*Flashover* research indicates in-deep knowledge. Some aspects, determine the *flashover* phenomenon, especially upper gas temperature  $\geq 550^{\circ}\text{C}$  and heat flux at floor level  $\geq 20 \text{ kW/m}^2$ . Both factors have to be considered together to define the initial point of this transition phase to fully developed fire. Furthermore, ventilation factor has a substantial impact on *flashover* occurrence. The location and size of the vents in the enclosure maintains a close relation to the development of this phenomenon. Vent identification using computer vision techniques [75] in real time could provide valuable information to predict *flashover*. Furthermore, *flashover* is clearly determined by an HRR/time relation, which could be a key issue for predicting with ANN models. Additionally, research is needed to differentiate *backdraft* from smoke explosions, a phenomenon that can occur in different situations. Also, better knowledge is required about the species concentration included and the unburned hydrocarbons involved. New research suggests that it is possible to predict and avoid *backdraft* by using temperature data.

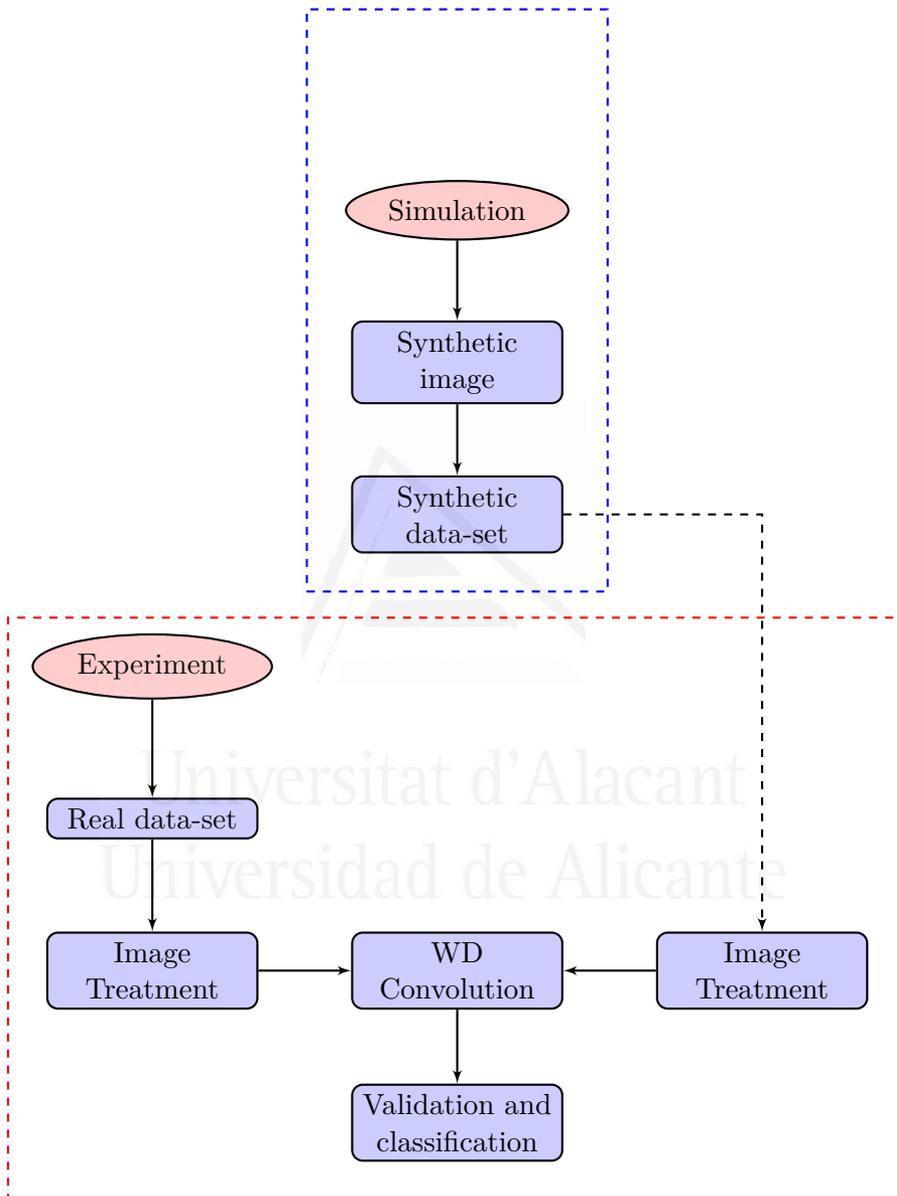
The simulations review from mathematical models reveal that computational fluid dynamics (CFD) simulation predominates over other analysed models. One of the many advantages of this type of simulation is the detailed analysis of thermal environments, which can be used to train and validate ANN with certain accuracy. Various CFD software packages have been compared in different articles shown in this review. In most cases FDS have been used to conduct research simulations. Not only have

been FDS validated with acceptable scores but also ANSYS CFX software obtained similar results. In particular, the use of FDS is widely extended because it is a free and open-source software tool. As a result, *flashover* phenomenon has been widely simulated in most of the articles reviewed. By contrast, some difficulties have been found to simulate *backdraft*.

Concerning TC, it is essential to remark that according to the reviewed articles it is not possible to compare FDS simulations with thermal image obtained directly from TC. Some transformations need to be done before this step, since the final image depends on the technical thermal camera parameters and medium conditions (scattering or non-scattering medium). This should be taken into account for developing artificial intelligence technology based in TC to use CFD techniques to train ANN's. Article review suggest that it is possible to obtain images from CFD software similar to a specific thermal imaging camera using its technical parameters. Programming and computer vision techniques can be used to conduct the mathematical calculations to achieve the final result.

#### A.1.4. Image modelling

The **method to generate the synthetic images data-set** requires a series of steps to obtain a useful image for *flashover* forecasting. All the steps to generate the synthetic data-set for the proposed method can be followed in the figure [A.5](#), blue dashed line process. For this work Fire Dynamics Simulator (FDS) [\[3\]](#) was used to simulate a *flashover* situation based in two small scale experiments. Many studies [\[9, 19, 52, 85, 89\]](#) have carried out enclosure fire simulations using this tool, evidencing its capability to make accurate simulations. However, it is impossible to compare directly data from this software with TC data. Some transformations have to be done to obtain time-dependent quantitative images of the radiation intensity from smoke coming out of the enclosure vent. For this purpose, the gray gas model, Large Eddy Simulation (LES) scalar results, a narrow band radiation model [\[29\]](#), and the radiative transfer



**Figure A.5:** Method to generate the synthetic data-set (blue dashed line) and method to validate and classify the synthetic data-set (red dashed line)

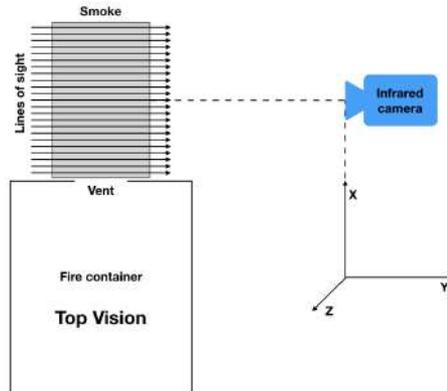
equation were used. Therefore, the radiative transfer equation used in this experiment is:

$$I = \int_{\lambda_1}^{\lambda_2} \alpha_\lambda I_\lambda(0) e^{-(\tau_\lambda)} d\lambda + \int_{\lambda_1}^{\lambda_2} \int_0^{\tau_\lambda} \alpha_\lambda I_{b\lambda}(\tau_\lambda^*) e^{-(\tau_\lambda - \tau_\lambda^*)} d\tau_\lambda^* d\lambda \quad (\text{A.1})$$

Where  $I_\lambda(0)$  and  $I_{b\lambda}$  are the intensities at the starting point along the trajectory and the spectral intensity of the black body respectively,  $\alpha_\lambda$  is the spectral coefficient of the thermal camera, and  $\lambda_1$  and  $\lambda_2$  are the filter bandwidth limits. The following equation represents the spectral optical thickness of the gases that make up the smoke layer, where  $K_\lambda$  is the spectral absorption coefficient and  $S$  is the length of the path.

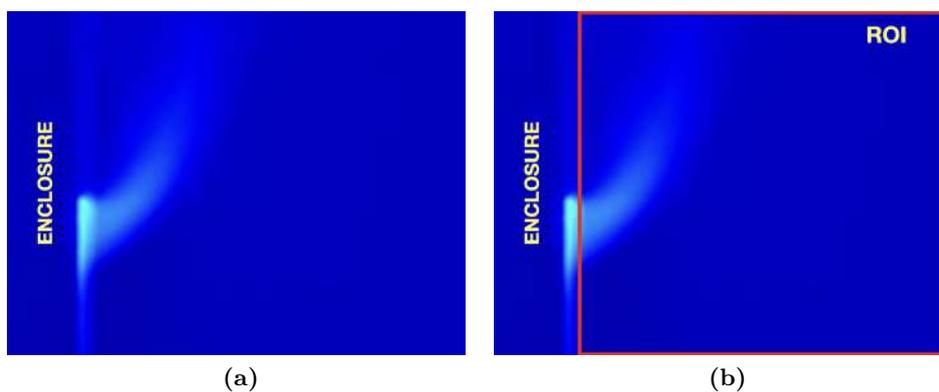
$$\tau_\lambda = \int_0^S K_\lambda ds \quad (\text{A.2})$$

The values of temperature, pressure, mole fraction of the gases involved and of products in suspension in the gas layer are used together with a narrow band radiation model (RADCAL) [30] to calculate the spectral absorption coefficient ( $K_\lambda$ ). Thermal radiation is calculated instantaneously, integrating along the lines of sight through the smoke layer (area of interest, see figure A.8), using the camera's spectral response, and integrating over the spectral range of the filter.

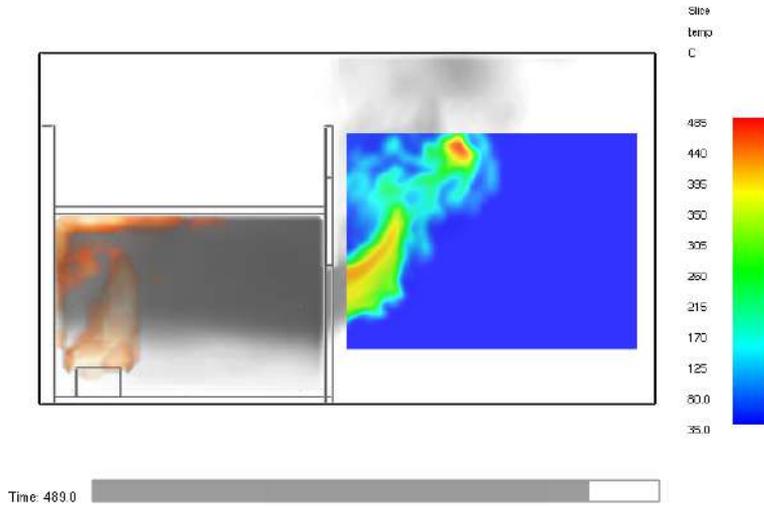


**Figure A.6:** Proposed method for generating synthetic images for *flashover* prediction. The lines of sight pass through the smoke (area of interest) towards the thermal camera.

Synthetic images data are stored in files every simulation second. Therefore the synthetic image data-set has as files as seconds has the simulation. Once the synthetic data-set is generated, to train artificial neural networks (ANN) with prediction purposes, an image validation is necessary. For this reason, two small scale *flashover* experiments (see figures [A.9](#) and [A.13](#)) and its corresponding simulations (see figures [A.14](#) and [A.10](#)) were carried out to validate the image with the proposed **Image Validation Method** developed in this research (see [A.5](#) red dashed line process). A radiometric thermal camera was located outside the enclosure to obtain the data for the validation process with simulation results. Finally, a quantitative comparison of images from a TC with computed images using the Wasserstein distance (WD) were carried out. To identify the capabilities and limitations of the WD for this case, two different real data-set are studied with this method. In the first one, the images are cropped a region of interest (ROI, see figure [A.7b](#)) and in the second one the images don't have any treatment (IMAGE, see figure [A.7a](#)). From the results presented (see figures [A.11](#), [A.12](#), [A.15](#) and [A.16](#)) is possible to conclude that although both image types (ROI and IMAGE) are capable of classifying the images in the corresponding stages using WD, high level of accuracy is achieved using the ROI image.



**Figure A.7:** Images from TC. (a) IMAGE (b) ROI.



**Figure A.8:** Area of interest in a simulation

**Table A.4:** Confusion matrix for experiment and simulation 1 ROI images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.

	R1	R2	R3	R4
S1	46	0	0	0
S2	5	486	0	0
S3	0	14	20	6
S4	0	0	15	59

**Table A.5:** Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 1 ROI images

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
Stage 1	90.20	100	100	100	99.23
Stage 2	97.20	96.67	98.98	96.15	97.08
Stage 3	57.14	96.75	50.00	97.69	94.64
Stage 4	90.77	97.40	79.73	97.35	96.77

**Table A.6:** Confusion matrix for experiment and simulation 1 IMAGE images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.

	<b>R1</b>	<b>R2</b>	<b>R3</b>	<b>R4</b>
<b>S1</b>	46	0	0	0
<b>S2</b>	5	500	4	0
<b>S3</b>	0	6	31	12
<b>S4</b>	0	0	0	64

**Table A.7:** Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 1 IMAGE images

	<b>TPR (%)</b>	<b>TNR (%)</b>	<b>PPV (%)</b>	<b>NPV (%)</b>	<b>ACC (%)</b>
<b>Stage 1</b>	90.20	100	100	99.20	99.25
<b>Stage 2</b>	98.81	94.44	98.23	96.23	97.75
<b>Stage 3</b>	88.57	97.16	63.26	99.35	96.70
<b>Stage 4</b>	84.21	100	100	98.01	98.20

**Table A.8:** Confusion matrix for experiment and simulation 2 ROI images. R1, R2, R3 and R4 represents the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.

	<b>R1</b>	<b>R2</b>	<b>R3</b>	<b>R4</b>
<b>S1</b>	33	15	0	0
<b>S2</b>	3	333	0	0
<b>S3</b>	0	15	45	0
<b>S4</b>	0	0	6	96

**Table A.9:** Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 2 ROI images

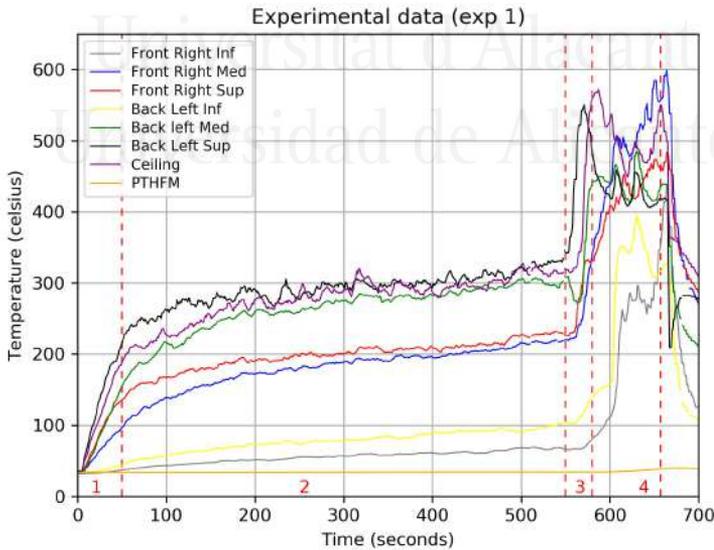
	<b>TPR (%)</b>	<b>TNR (%)</b>	<b>PPV (%)</b>	<b>NPV (%)</b>	<b>ACC (%)</b>
<b>Stage 1</b>	91.67	97.06	68.75	99.40	96.70
<b>Stage 2</b>	91.73	98.36	99.11	85.71	93.96
<b>Stage 3</b>	88.23	96.97	75.00	98.76	96.15
<b>Stage 4</b>	100	98.67	94.12	100	98.90

**Table A.10:** Confusion matrix for experiment and simulation 2 IMAGE images. R1, R2, R3 and R4 represent the different stages in the experiment. S1, S2, S3, and S4 are the stages for the simulation.

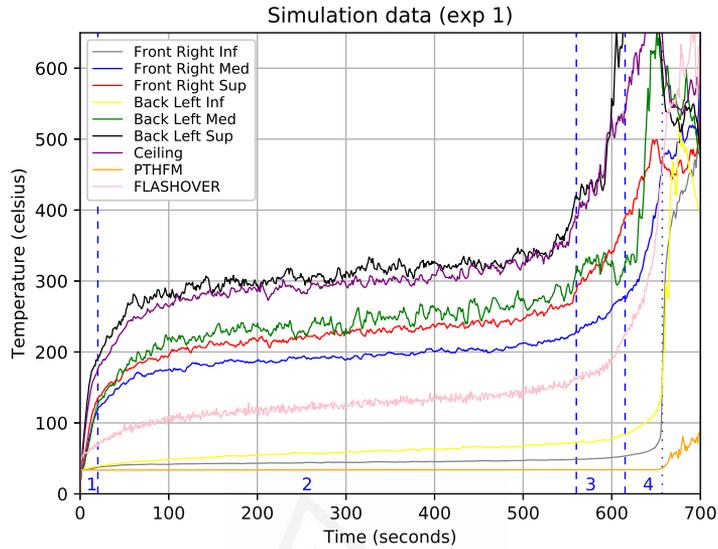
	R1	R2	R3	R4
S1	36	79	0	0
S2	0	286	36	0
S3	0	0	17	47
S4	0	0	0	49

**Table A.11:** Sensitivity, specificity, precision, negative predictive values and accuracy for experiment and simulation 2 ROI images

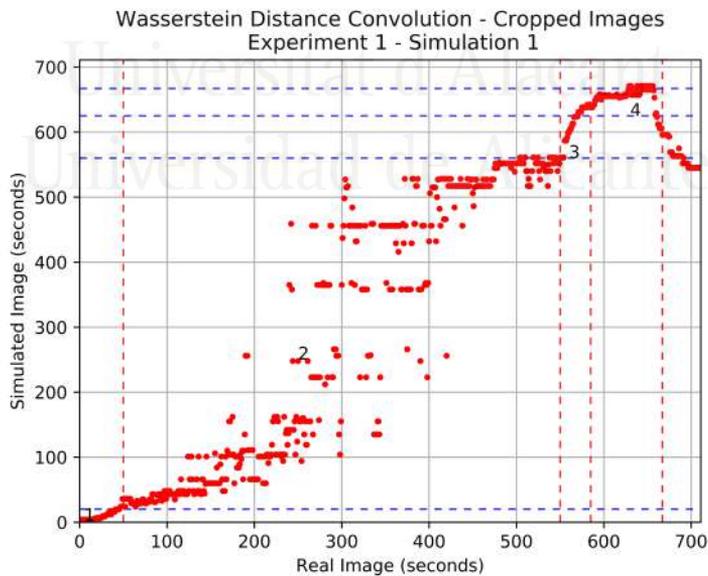
	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
Stage 1	100	80.63	31.30	100	85.64
Stage 2	78.36	80.54	88.82	65.35	79.09
Stage 3	32.07	90.54	26.56	92.59	84.90
Stage 4	51.40	100	100	90.62	91.45



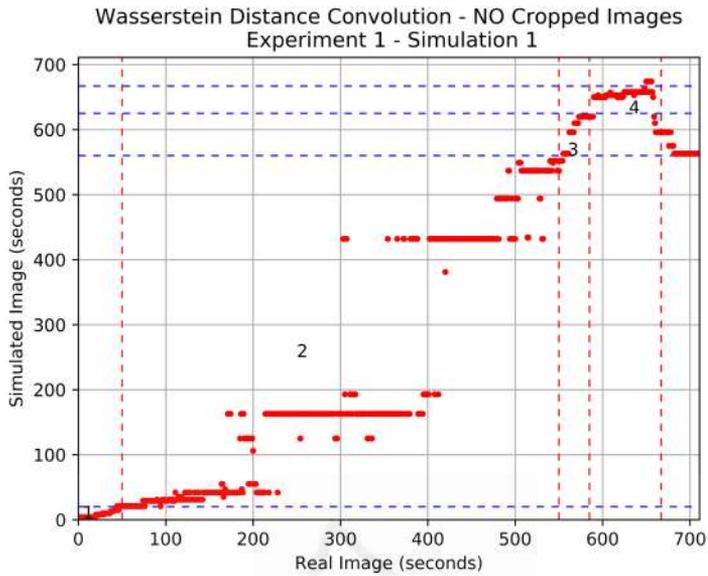
**Figure A.9:** Data from sensors in experiment 1. Numbers 1, 2, 3 and 4 represents different stages in the experiment surrounded by red dash lines.



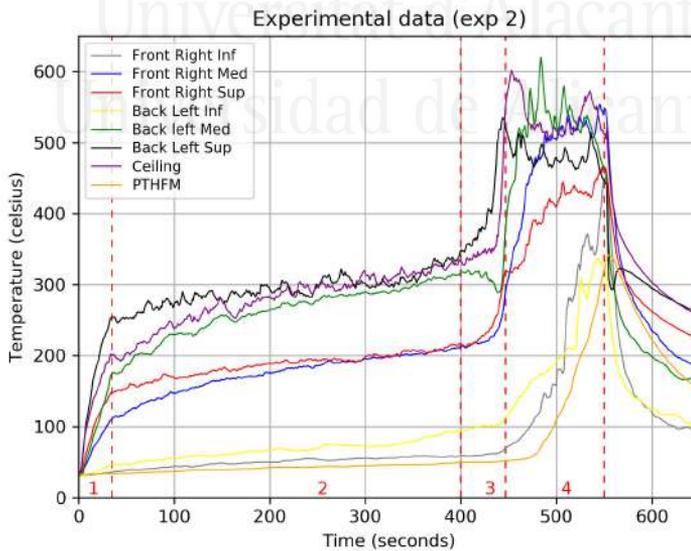
**Figure A.10:** Data from sensors in simulation1. Numbers 1, 2, 3 and 4 represents different stages in the simulation surrounded by blue dash lines.



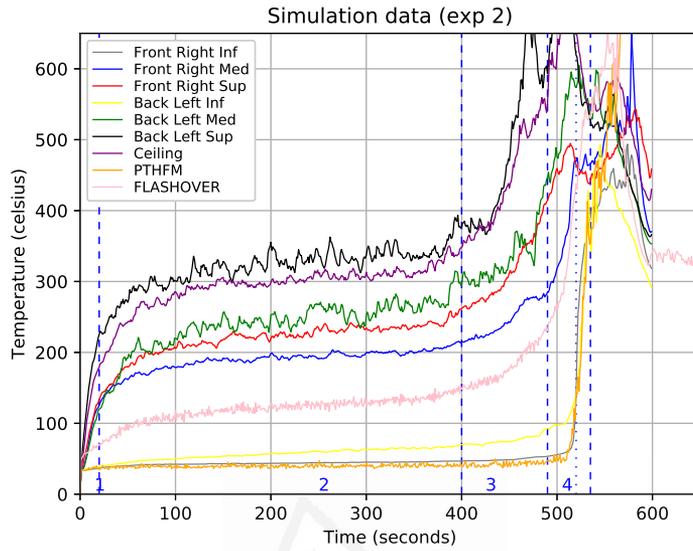
**Figure A.11:** WD convolution between thermal camera and simulation ROI images in experiment 1. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines.



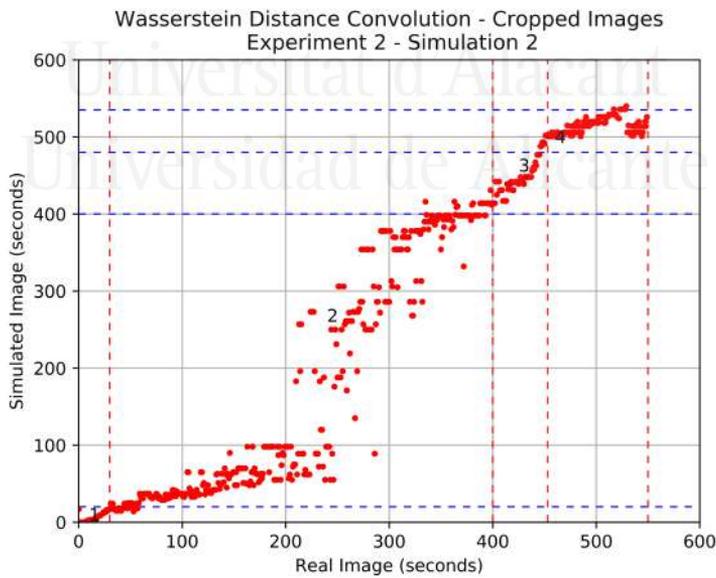
**Figure A.12:** WD convolution between thermal camera and simulation IMAGE images in experiment 1. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines.



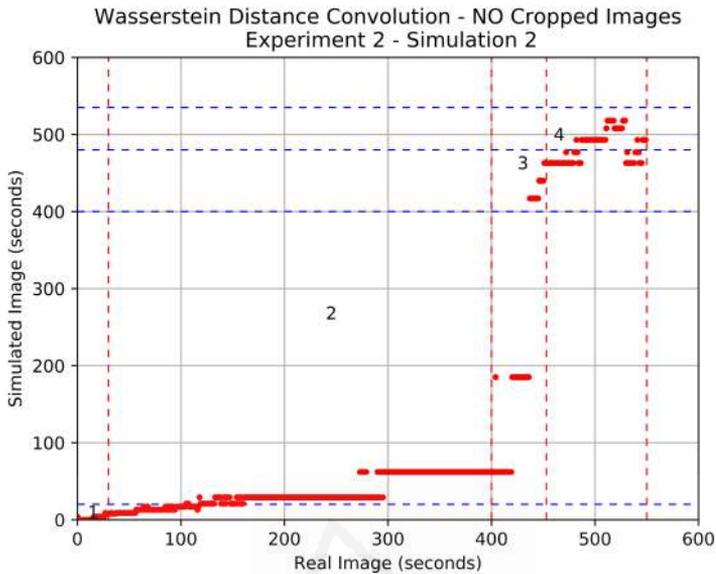
**Figure A.13:** Data from sensors in experiment 2. Numbers 1, 2, 3 and 4 represents different stages in the experiment surrounded by red dash lines.



**Figure A.14:** Data from sensors in simulation 2. Numbers 1, 2, 3 and 4 represents different stages in the simulation surrounded by blue dash lines



**Figure A.15:** WD convolution between thermal camera and simulation ROI images in experiment 2. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines



**Figure A.16:** WD convolution between thermal camera and simulation IMAGE images in experiment 2. Numbers 1, 2, 3 and 4 represents different stages surrounded by dash lines.

### A.1.5. Prediction method

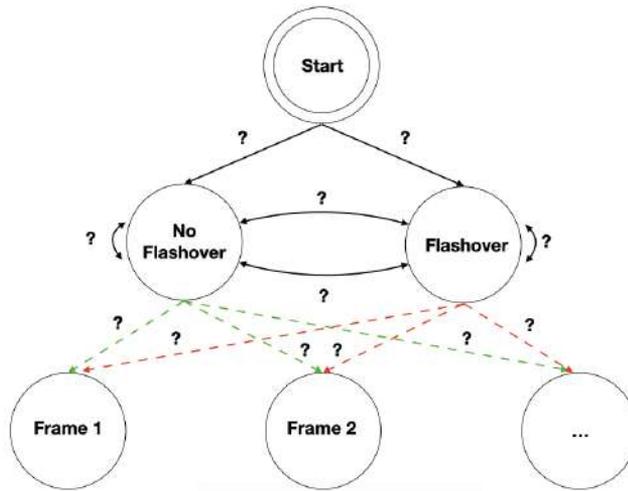
Based on the above, it is possible to divide the fire curve in different stages (see figure [A.2a](#), Ignition, Growth, *flashover*, Fully Developed and Decay) with the information provided by the sensors placed inside the enclosure. It is logical to think that a direct relationship can be established between the information from the sensors and the images captured outside the enclosure with the thermal image camera, to establish in what stage the the fire's evolution is. For that reason, **Hidden Markov Models (HMM)** have been considered in the **prediction method**. By applying HMM, it is possible that the number of stages can be identified (hidden states for the observer) to make an optimal prediction using the images captured with the thermal vision camera.

$Q = q_1 q_2 \dots q_N$	a set of $N$ states
$A = a_{11} \dots a_{ij} \dots a_{NN}$	a transition probability matrix $A$ , each $a_{ij}$ representing the probability of moving from state $i$ to state $j$ , s.t $\sum_{j=1}^N a_{ij} = 1 \forall i$
$O = o_1 o_2 \dots o_T$	a sequence of $T$ observations
$B = b_i(o_t)$	a sequence of observation likelihoods, also called emission probabilities, each expressing the probability of an observation $o_t$ being generated from a state $i$
$\pi = \pi_1, \pi_2, \dots, \pi_N$	an initial probability distribution over states. $\pi_i$ is the probability that the Markov chain will start in state $i$ . Some states $j$ may have $\pi_j = 0$ , meaning that they cannot be initial states. Also $\sum_{i=1}^N \pi_i = 1$

**Table A.12:** Hidden Markov Model Parameters

Regarding HMM parameters, different classifier configurations (see table [A.12](#)) have been studied to find the optimal model for this work. In this case the parameter  $O$  is made with frames from a particular simulation. The problem is: given the sequence  $O$  and the number of hidden states, what is the optimal model that maximises the  $O$ 's probability? (learning of the  $A$  and  $B$  parameters). Each observation from a sequence is a characteristic vector of a thermal camera image. In this research four kind of characteristic vectors have been considered to study, WD, typical deviation, the sum of image column and the sum of image rows. Previously to this step, it is important to consider that, the ambient temperature is variable and it depends on multiple factors. For this reason, an image treatment has been considered before to train the model. To do that, a temperature value was chosen as a limit, below this point, data were not considered relevant for *flashover* prediction.

To train and validate the obtained models, 65 simulation were carried out (see table [B.1](#)) with different configurations for this purpose. of which 23 were designed for non-*flashover* occurrence and 42 for *flashover*. A total of 48 different models with 2 hidden states from 4 proposed sequences were analysed in order to find the best configuration. The Receiver Operating

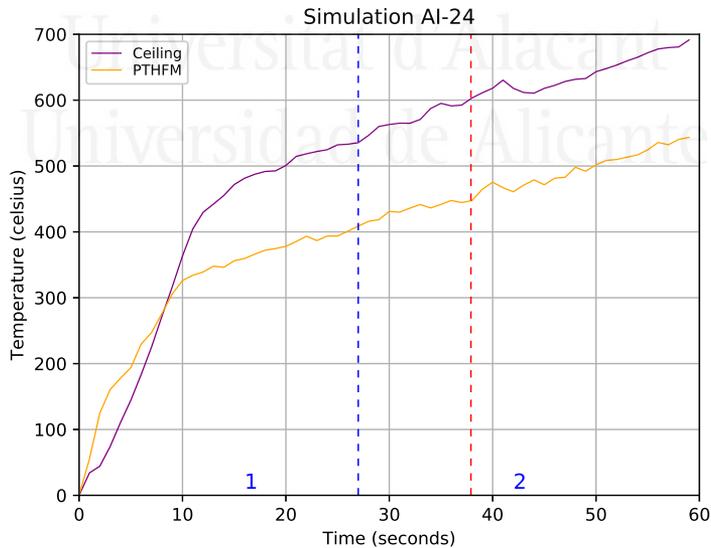


**Figure A.17:** Model for the proposed case of *flashover* prediction with two hidden states (No *flashover* and *flashover*) and different observable states (frames).

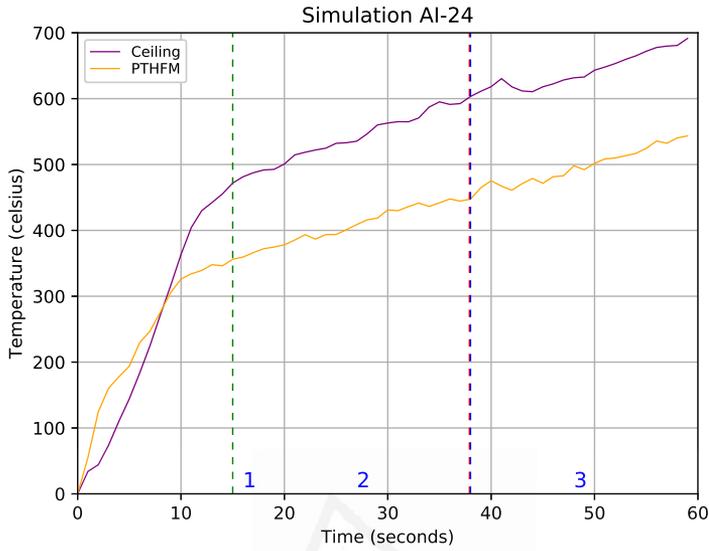
Characteristic (ROC) curve and the area under the curve (AUC) have been used to do that. Once this step was completed, 12 models (see table [A.13](#)) from 3 different sequences were studied, including the optimal classifier configuration, with a different number of hidden states (from 2 to 5). Classifiers with two and three hidden states from AI-24 simulation, get the higher values according to the AUC results obtained from simulations. The models have problems to classify the sequence correctly where the fire curve is horizontal (constant heat release rate). This problem was already mentioned in the model based image verification method proposed in this research and it occurs due the image similarity in this cases. Despite this circumstance, two and three hidden states model from AI-24 can be use to predict flash over with accuracy (see table [A.16](#)). Furthermore, prediction with tree hidden states models can be done with the highest time gap.

**Table A.13:** Results of the tests carried out to determine the vector of characteristics with thermal imaging treatment using simulations AI-24, AI-25 and AI-41.

Nº	Sim	EO	ROC	Vector	AUC
1	AI-24	2	Frame	WD	0.85
2	AI-24	3	Frame	WD	0.77
3	AI-24	4	Frame	WD	0.78
4	AI-24	5	Frame	WD	0.69
5	AI-25	2	Frame	WD	0.68
6	AI-25	3	Frame	WD	0.68
7	AI-25	4	Frame	WD	0.68
8	AI-25	5	Frame	WD	0.68
9	AI-41	2	Frame	WD	0.73
10	AI-41	3	Frame	WD	0.64
11	AI-41	4	Frame	WD	0.64
12	AI-41	5	Frame	WD	0.57



**Figure A.18:** HMM for 2 states in AI-24 simulation. The red vertical line corresponds to the prediction based on the observed data. The blue vertical line divides the fire curve in the 2 states according to the proposed model.



**Figure A.19:** HMM for 3 states in AI-24 simulation. Red vertical line corresponds to prediction based on observed data. The vertical green and blue lines divide the fire curve into 3 states according to the proposed model.

		Observation	
		Positive	Negative
Prediction	Positive	41	14
	Negative	0	9

**Table A.14:** Confusion matrix for the 2 hidden state model (AI-24) obtained from applying the model to the 64 remaining simulations.

		Observation	
		Positive	Negative
Prediction	Positive	39	14
	Negative	2	9

**Table A.15:** Confusion matrix for the 3 hidden state model (AI-24) obtained from applying the model to the 64 remaining simulations.

**Table A.16:** Sensitivity, specificity, precision, negative predictive values and accuracy for the 2 and 3-state models studied from the AI-24 simulation.

	TPR (%)	TNR (%)	PPV (%)	NPV (%)	ACC (%)
<b>HMM 2 states</b>	100	39.13	74.54	100	78.12
<b>HMM 3 states</b>	95.12	39.13	73.58	81.81	75

The confusion matrices analysis reveals a high number of false positives, 14 simulations are predicted as false positives since the model has found the corresponding hidden states in the sequence. But according to the sensors data and the parameters that have been considered for the occurrence of this phenomenon, it does not take place.

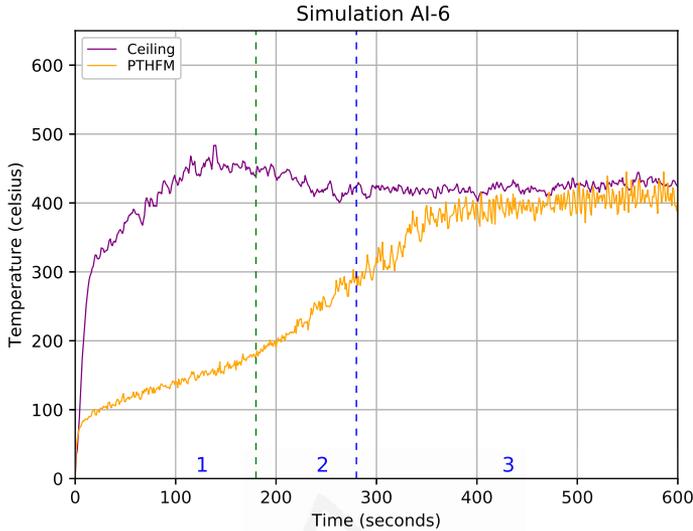
The analysis of these simulations reveals that certain conditions are very interesting and can trigger *flashover*. The figure [A.20](#) shows the ceiling and floor sensors records in the AI-6 (FP) simulation including the hidden states predicted by Markov models. Although the ceiling sensor registers temperature values below 500°C, the temperature corresponding to the PTHFM sensor reaches values very close to the second *flashover* condition (454°C). This suggests that the materials at ground level would be very close to the critical radiation (20 kW/m<sup>2</sup>) and therefore it would be facing a very hazardous scenario. For this reason, false positives have to be the object of a more in-depth study to determine how the prediction model behaves in these cases.

To validate the model obtained, it was applied using synthetic data from simulation 2 (see figures [A.21](#) and [A.22](#)) and real data from experiment 4 (see figures [A.23](#) and [A.24](#)).

Finally, an equation for time prediction (see equation [A.3](#)) to the point of interest (could be the end of the state or *flashover*) is presented in this work.

$$t_i = \frac{WD_{ref} \cdot t_{obs}}{WD_{obs}} \quad (\text{A.3})$$

Where  $t_i$  is the time to the point of interest,  $WD_{obs}$  and  $t_{obs}$  are the Wasserstein distance and the time between the two corresponding

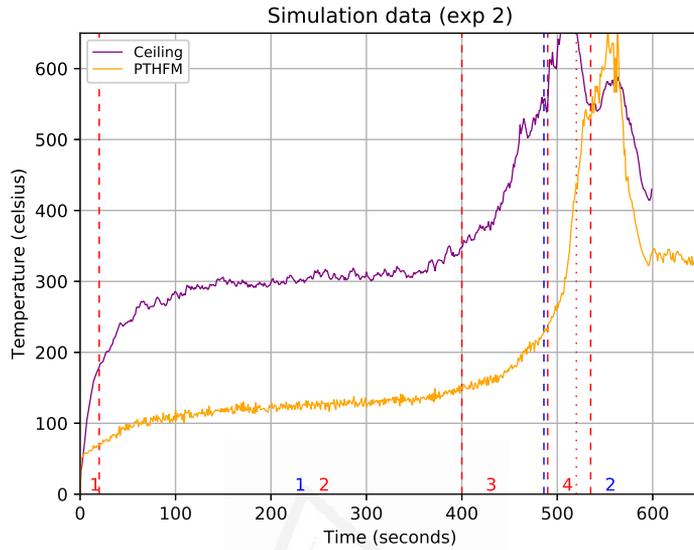


**Figure A.20:** HMM with 3 hidden states in experiment in simulation AI-6. The red vertical lines divide the fire curve in the observed states and the blue lines in the hidden states according to the model.

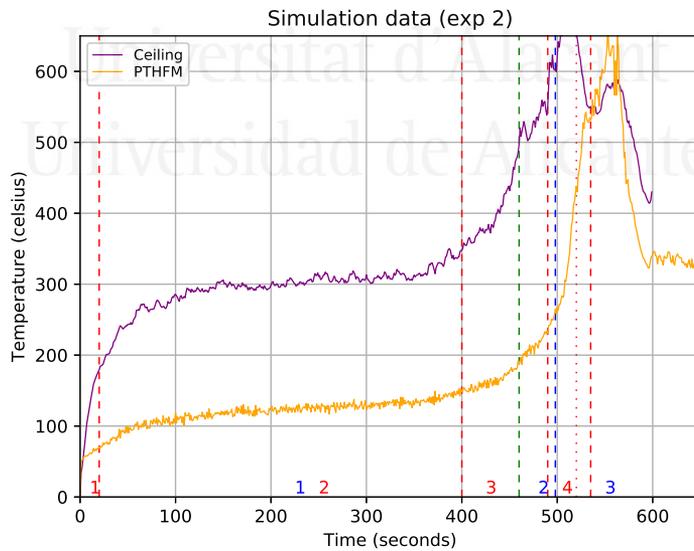
observation images to perform the calculation and  $WD_{ref}$  is the Wasserstein distance for the point of interest in the reference simulation. This equation must be considered taking into account the fire evolution.

## A.2. Conclusions and future work

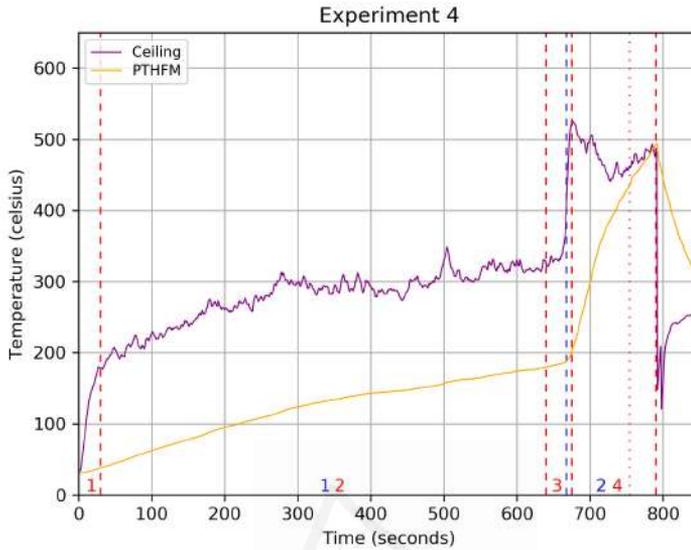
Real complex scenarios with different vents and fuels have not been evaluated with regard to the *flashover* phenomenon. Reduced-scale experiments with a simple configuration are used to study this kind of situation. However, to determinate the occurrence of *flashover*, not only do gas layer temperature and heat flux radiation at floor level need to be considered but also ventilation factor and HRR/time. For this reason, other configurations of the enclosure should be analysed. Chemical and physical aspects of *backdraft* need to be researched to acquire deep knowledge about this kind of phenomenon (to the best of my knowledge), like the contribution of unburned hydrocarbons with different fuels.



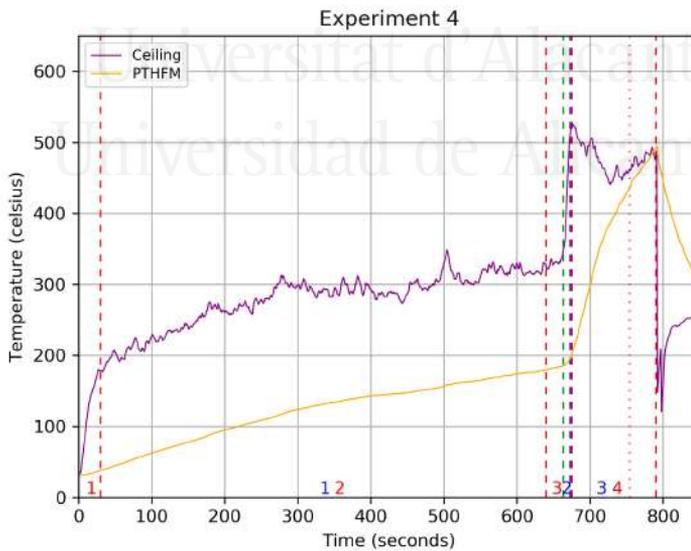
**Figure A.21:** HMM with 2 hidden states in the simulation of experiment 2. The red vertical lines divide the fire curve in the observed states and the blue lines in the hidden states according to the model.



**Figure A.22:** HMM with 3 hidden states in the simulation of experiment 2. The red vertical lines divide the fire curve in the observed states and the blue and green lines in the hidden states according to the model.



**Figure A.23:** HMM with 2 hidden states in experiment 4. The red vertical lines divide the fire curve in the observed states and the blue lines in the hidden states according to the model.



**Figure A.24:** HMM with 3 hidden states in experiment 4. The red vertical lines divide the fire curve in the observed states and the blue and green lines in the hidden states according to the model.

Although *flashover* is well simulated using different CFD software, it was difficult to find such simulations of *backdraft* phenomenon, underscoring the challenge of carrying out more research to simulate the *backdraft* phenomenon correctly.

Some research regarding *flashover* prediction using ANN was identified but any research has been found that predicts this phenomenon with TC's using data-sets from CFD software in order to train ANN's. However, no study has been found on *backdraft* prediction using ANN. This represents a future line of research considering that *backdraft* is a hazardous situation for firefighters.

Regarding the model-based imaging of mid-infrared radiation for *flashover* prediction in confined fires. Two experiments were carried out and WD convolution between real and simulated images were used to perform a quantitative study of the results to validate that. The WD convolution with ROI images reveals high accuracy to carry out quantitative studies. In fact, the comparison presented between data from real and simulation sensors match with those of the WD convolution results. Some uncertainty emerges when the intensity and shapes of images are very similar for a continued period of time, and in this case the accuracy is lower. Furthermore, this research shows that it is possible to know if the heat release rate of the simulation is higher or lower than for the real case. Moreover, the WD convolution with IMAGE images does not reveal the same degree of accuracy, thereby making comparison difficult. Confusion matrices for the method using the two image types exposed in this work (ROI and IMAGE images) show a high degree of accuracy (see tables [A.4](#), [A.6](#), [A.8](#) and [A.10](#)). The results suggest that it is possible to carry out an accurate image classification in different stages using thermal camera images taken from different distances and positions. In addition to that, the WD for IMAGE images can deliver a more than acceptable classification that includes part of the enclosure in the image.

From the results presented, it is possible to conclude that the method

proposed in this work can be used to obtain images from the smoke outside the enclosure that are similar to those obtained from TC's. I envisage future research on using WD convolution as an additional method to validate simulation images against real results from ROI thermal camera images.

The proposed method to predict the *flashover* occurrence, shows that it is possible to predict *flashover* with accuracy for one vent enclosure. Furthermore, an equation to estimates the time for flashover prediction is presented for the prediction method proposed in this work. Additional research is necessary to train and validate the model with different configurations and vents to study the classifier accuracy. WD combined with hidden Markov models can identify stages in the fire development, which is taking into account to predict *flashover*. Different classifiers to predict *flashover* such as deep learning, Long short-term memory (LSTM), Support Vector Machines (SVM), decision trees and even establish hybrid methods with fuzzy logic to divide images phases, can be studied as a future research. The study of the of model's behavior in the case of false positives would increase the efficiency of the classifier and could help to redefine compromised situations in this class of emergencies.

Considering the encouraging results present in this study, the proposed method using 2 or 3 hidden states could be implemented by fire services to predict the *flashover* phenomenon.

---

Apéndice B

# Configuración de las simulaciones

---



Universitat d'Alacant  
Universidad de Alicante

**Tabla B.1:** Configuración de las simulaciones

NºSIM	MAT	DIMEMSIONES	VENT(1)	VENT(2)	COMB(1)	COMB(2)	COMB(3)	DUR	FLASH
AI-01	AC	64x41.5x41.5	15x28	0 0	Gasolina	8X8	B-L	90	0
AI-02	AC	64x41.5x41.5	15x28	0 0	Gasolina	8X8	M-R	91	0
AI-03	AC	64x41.5x41.5	15x28	0 0	Gasolina	8X8	F-L	134	0
AI-04	AC	64x41.5x41.5	15x28	0 0	Gasolina	12X12	F-L	600	0
AI-05	AC	64x41.5x41.5	15x28	0 0	Gasolina	12X12	M-R	600	0
AI-06	AC	64x41.5x41.5	15x28	0 0	Gasolina	12X12	B-L	600	0
AI-07	AC	64x41.5x41.5	15x15	0 0	Gasolina	8X8	B-L	259	0
AI-08	AC	64x41.5x41.5	15x15	0 0	Gasolina	8X8	M-R	246	0
AI-09	AC	64x41.5x41.5	15x15	0 0	Gasolina	8X8	F-L	290	0
AI-10	AC	64x41.5x41.5	15x15	0 0	Gasolina	12X12	F-L	600	0
AI-11	AC	64x41.5x41.5	15x15	0 0	Gasolina	12X12	M-R	600	0
AI-12	AC	64x41.5x41.5	15x15	0 0	Gasolina	12X12	B-L	600	0
AI-13	AC	64x41.5x41.5	15x28	0 0	Gasolina	12X16	B-L	600	0
AI-14	AC	64x41.5x41.5	15x28	0 0	Gasolina	14X17	B-L	600	0
AI-15	AC	64x41.5x41.5	15x28	0 0	Madera	12x17x7	B-L	567	0
AI-16	AB	64x41.5x41.5	15x28	0 0	Madera	12x17x7	B-L	73	63.20
AI-17	AB	64x41.5x41.5	15x15	0 0	Madera	12x17x7	B-L	74	63.04

Continúa en la página siguiente.

NºSIM	MAT	DIM(CM)	VENT(1)	VENT(2)	COMB(1)	COMB(2)	COMB(3)	DUR	FLASH
AI-18	AB	64x41.5x41.5	15x28	0 0	Gasolina	14X17	B-L	24	13.76
AI-19	AB	64x41.5x41.5	15x15	0 0	Gasolina	14X17	B-L	26	9.8
AI-20	AB	64x60x41.5	15x15	0 0	Gasolina	14X17	B-L	600	36.32
AI-21	AB	64x60x41.5	15x28	0 0	Gasolina	14X17	B-L	69	28.16
AI-22	AB	64x60x41.5	15x28	22 28	Gasolina	14X17	B-L	67	31.52
AI-23	AB	64x64x41.5	15x15	0 0	Madera	12x17x7	B-L	600	0
AI-24	AB	64x60x50	15x28	0 0	Gasolina	14X17	B-L	59	37.92
AI-25	AB	64x41.5x45	15x28	0 0	Madera	12x17x7	B-L	114	93.60
AI-26	AB	64x41.5x50	15x28	0 0	Madera	12x17x7	B-L	115	94.40
AI-27	AB	64x72x41.5	15x28	0 0	Madera	12x17x7	B-L	103	88.48
AI-28	AB	64x72x41.5	15x28	22 28	Gasolina	14X17	B-L	63	33.12
AI-29	AB	64x72x45	15x28	0 0	Madera	12x17x7	B-L	110	88.64
AI-30	AB	64x72x50	15x28	0 0	Madera	12x17x7	B-L	109	88.48
AI-31	AB	64x72x45	15x28	22 28	Gasolina	14X17	B-L	53	32.48
AI-32	AB	64x72x50	15x28	22 28	Gasolina	14X17	B-L	53	32.16
AI-33	AB	64x72x50	15x15	22 28	Gasolina	14X17	B-L	558	0
AI-34	AB	64x72x45	15x15	22 28	Gasolina	14X17	B-L	551	0
AI-35	AB	64x72x41.5	15x15	22 28	Gasolina	14X17	B-L	280	0
AI-36	AB	64x60x50	15x28	0 0	Madera	12x17x7	B-L	207	109.44

Continúa en la página siguiente.

NºSIM	MAT	DIM(CM)	VENT(1)	VENT(2)	COMB(1)	COMB(2)	COMB(3)	DUR	FLASH
AI-37	AB	64x60x45	15x28	0 0	Madera	12x17x7	B-L	211	107.84
AI-38	AB	64x60x41.5	15x28	0 0	Madera	12x17x7	B-L	129	109.12
AI-39	AB	64x60x41.5	15x28	0 0	Madera	12x17x7	F-L	193	119.20
AI-40	AB	64x60x45	15x28	0 0	Madera	12x17x7	F-L	141	120.48
AI-41	AB	64x60x50	15x28	0 0	Madera	12x17x7	F-L	147	126.08
AI-42	AB	64x72x50	15x28	0 0	Madera	12x17x7	F-L	141	120.16
AI-43	AB	64x72x45	15x28	0 0	Madera	12x17x7	F-L	140	119.68
AI-44	AB	64x72x41.5	15x28	0 0	Madera	12x17x7	F-L	139	117.44
AI-45	AB	64x72x41.5	15x20	0 0	Madera	12x17x7	F-L	378	118.72
AI-46	AB	64x72x45	15x20	0 0	Madera	12x17x7	F-L	231	120.64
AI-47	AB	64x72x50	15x20	0 0	Madera	12x17x7	F-L	228	122.88
AI-48	AB	64x60x50	15x20	0 0	Madera	12x17x7	F-L	178	121.60
AI-49	AB	64x60x45	15x20	0 0	Madera	12x17x7	F-L	238	122.56
AI-50	AB	64x60x41.5	15x20	0 0	Madera	12x17x7	F-L	237	119.20
AI-51	AB	64x41.5x45	15x28	0 0	Gasolina	14X17	B-L	31	9.76
AI-52	AB	64x41.5x50	15x28	0 0	Gasolina	14X17	B-L	35	12.80
AI-53	AB	64x60x45	14x30	22 28	Gasolina	14X17	B-L	47	26.56
AI-54	AB	64x41.5x41.5	14x30	0 0	Gasolina	14X17	B-L	38	16.32
AI-55	AB	64x41.5x45	14x30	0 0	Gasolina	14X17	B-L	36	14.56

Continúa en la página siguiente.

NºSIM	MAT	DIM(CM)	VENT(1)	VENT(2)	COMB(1)	COMB(2)	COMB(3)	DUR	FLASH
AI-56	AB	64x41.5x50	14x30	0 0	Gasolina	14X17	B-L	36	15.20
AI-57	AB	64x60x41.5	14x30	0 0	Gasolina	14X17	B-L	51	25.76
AI-58	AB	64x60x45	14x30	0 0	Gasolina	14X17	B-L	50	28.00
AI-59	AB	64x60x50	14x30	0 0	Gasolina	14X17	B-L	50	28.32
AI-60	AB	64x60x55	14x30	0 0	Gasolina	14X17	B-L	48	27.20
AI-61	AB	64x41.5x55	14x30	0 0	Gasolina	14X17	B-L	38	17.28
AI-62	AC	64x41.5x55	14x30	0 0	Gasolina	14X17	B-L	306	0
AI-63	AC	64x41.5x50	14x30	0 0	Gasolina	14X17	B-L	311	0
AI-64	AC	64x41.5x45	14x30	0 0	Gasolina	14X17	B-L	316	0
AI-65	AC	64x41.5x41.5	14x30	0 0	Gasolina	14X17	B-L	311	0

Universitat d'Alacant  
 Universidad de Alicante



Universitat d'Alacant  
Universidad de Alicante

# Bibliografía

---

- [1] CFAST, Fire Growth and Smoke Transport Modeling | NIST. [26](#)
- [2] FAST ver. 3.1.6 developed by National Institute of Standards and Technology (NIST). [39](#)
- [3] FDS-fire dynamics simulator, NIST. [28](#), [53](#), [150](#)
- [4] National Fire Protection Association. [XXVII](#), [XXIX](#), [5](#), [7](#), [140](#), [141](#)
- [5] OpenCV. <https://opencv.org/>. [71](#)
- [6] POT:Python Optimal Transport. [71](#)
- [7] Python 3.7.7 Documentation. <https://docs.python.org/3.7/>. [51](#), [71](#)
- [8] World Fire Statistics. Tech. rep., 2018. [XVII](#), [XXII](#), [5](#), [6](#), [139](#), [140](#)
- [9] ARAVIND KUMAR, A., KUMAR, R., AND JAIN, S. Application of Computational Fluid Dynamics for Different Fire Strengths in a Compartment Using Combustion Modelling. *Fire Sci. Technol.* 33, 2 (2014), 35–46. [28](#), [33](#), [50](#), [150](#)
- [10] BABRAUSKAS, V. Estimating room flashover potential. *Fire Technol.* 17, 1 (feb 1981), 94–103. [20](#), [21](#), [22](#), [25](#), [50](#)
- [11] BABRAUSKAS, V., PEACOCK, R. D., AND RENEKE, P. A. Defining flashover for fire hazard calculations: Part II. *Fire Saf. J.* 38, 7 (nov 2003), 613–622. [21](#), [23](#), [25](#), [50](#)

- [12] BAUM, L. B., AND EAGON, J. A. An inequality with applications to statistical estimation for probabilistic functions of markov processes and to a model for ecology. *Bull. Am. Math. Soc.* 73, 3 (1967), 360–363. [92](#)
- [13] BAUM, L. E., AND PETRIE, T. Statistical Inference for Probabilistic Functions of Finite State Markov Chains. *Ann. Math. Stat.* 37, 6 (dec 1966), 1554–1563. [92](#), [96](#)
- [14] BEARD, A. N. Fire Models and Design. *Fire Saf. J.* 28 (1997), 117–138. [26](#)
- [15] BISHOP, S. R., AND DRYSDALE, D. D. Fires in compartments: the phenomenon of flashover. *R. Soc.* (1998). [21](#)
- [16] BOURNE, D. P. A Brief Introduction to Optimal Transport Theory. 1–12. [63](#)
- [17] CHEN, A., FRANCIS, J., DONG, X., AND CHEN, W. An experimental study of the rate of gas temperature rise in enclosure fires. *Fire Saf. J.* 46, 7 (oct 2011), 397–405. [21](#)
- [18] CHOW, W. K. A Comparison of the Use of Fire Zone and Field Models for Simulating Atrium Smoke-filling Processes. *Fire Saf. J. Copyr.* 25 (1995), 337–353. [27](#), [33](#)
- [19] CHOW, W.-K. Evaluation of the Field Model, Fire Dynamics Simulator, for a Specific Experimental Scenario Combustion Chemistry View project. *Artic. J. Fire Prot. Eng.* (2005). [29](#), [33](#), [50](#), [150](#)
- [20] CORTÉS, D., GIL, D., AND AZORÍN, J. Revisión del modelado y simulación para la predicción de explosiones en incendios de espacios confinados. In *Res. Adv. Technol. Fire Saf.* (Cantabria, 2017), Universidad de Cantabria, Ed. [134](#)
- [21] CORTÉS, D., GIL, D., AND AZORÍN, J. Fire Science Living Lab for Flashover Prediction. *Proceedings* 31, 1 (nov 2019), 87. [133](#)

- [22] CORTÉS, D., GIL, D., AZORÍN, J., VANDECASTEELE, F., AND VERS-TOCKT, S. A Review of Modelling and Simulation Methods for Flashover Prediction in Confined Space Fires. *Appl. Sci.* 10, 16 (aug 2020), 5609. [133](#)
- [23] EVEGREN, F., AND WICKSTRÖM, U. New approach to estimate temperatures in pre-flashover fires: Lumped heat case. *Fire Saf. J.* 72 (feb 2015), 77–86. [25](#), [30](#), [33](#)
- [24] FLEISCHMANN, C. M., AND CHEN, Z. Defining the difference between backdraft and smoke explosions. *Procedia Eng.* 62 (2013), 324–330. [21](#), [24](#), [25](#)
- [25] FLEISCHMANN, C. M., PAGNI, P. J., AND WILLIAMSON, R. B. Quantitative Backdraft Experiments. *Fire Saf. Sci.* 4 (1994), 337–348. [21](#)
- [26] FORNEY, G. D. The Viterbi Algorithm. *Proc. IEEE* 61, 3 (1973), 268–278. [95](#)
- [27] GOJKOVIC, D. Initial Backdraft Experiments. Tech. rep. [12](#), [31](#), [145](#)
- [28] GRIMWOOD, P., AND DESMET, K. TACTICAL FIREFIGHTING. Tech. rep., 2003. [12](#), [145](#)
- [29] GROSSHANDLER, W. L. RADCAL: A Narrow-Band Model for Radiation Calculations in a Combustion, Environment. Tech. rep., 1993. [51](#), [150](#)
- [30] GROSSHANDLER, W. L. RADCAL: A Narrow-Band Model for Radiation Calculations in a Combustion, Environment. Tech. rep., 1993. [61](#), [152](#)
- [31] GUORONG XUAN, WEI ZHANG, AND PEIQI CHAI. EM algorithms of Gaussian mixture model and hidden Markov model. In *Proc. 2001 Int. Conf. Image Process. (Cat. No.01CH37205)* (2001), vol. 1, IEEE, pp. 145–148. [100](#)

- [32] HORNG, W. B., AND PENG, J. W. Image-based fire detection using neural networks. *Proc. 9th Jt. Conf. Inf. Sci. JCIS 2006 2006*, January 2006 (2006). [148](#)
- [33] HORVAT, A., AND SINAI, Y. Numerical simulation of backdraft phenomena. *Fire Saf. J.* 42, 3 (apr 2007), 200–209. [26](#), [31](#), [33](#)
- [34] HUO, R., JIN, X. H., SHI, C. L., AND CHOW, W. K. ON THE EQUATIONS FOR FLASHOVER FIRE IN SMALL COMPARTMENTS. *Int. J. Eng. Performance-Based Fire Codes* 3, 4 (2001), 158–165. [21](#), [22](#)
- [35] HUSEYNOV, J., BOGER, Z., SHUBINSKY, G., AND BALIGA, S. Optical flame detection using large-scale artificial neural networks. In *Proceedings. 2005 IEEE Int. Jt. Conf. Neural Networks, 2005.* (2005), vol. 3, IEEE, pp. 1959–1964. [37](#), [43](#), [148](#)
- [36] HUSEYNOV, J. J., AND BALIGA, S. B. Optical infrared flame detection system with neural networks. In *Proc. SPIE - Int. Soc. Opt. Eng.* (sep 2007), F. T. Luk, Ed., p. 66970L. [37](#), [43](#), [148](#)
- [37] INGBERG, S. H. Tests of the Severity of Building Fires. *Q. Natl. Fire Prot. Assoc.* 22 (1928), 43–61. [20](#), [21](#)
- [38] JOHNSON, R., WU, H., AND IHME, M. A general probabilistic approach for the quantitative assessment of LES combustion models. *Combust. Flame* 183 (sep 2017), 88–101. [36](#)
- [39] KACEM, A., LALLEMAND, C., GIRAUD, N., MENSE, M., DE GENARO, M., PIZZO, Y., LORAUD, J.-C., BOULET, P., AND PORTERIE, B. A small-world network model for the simulation of fire spread onboard naval vessels. *Fire Saf. J.* 91, February (jul 2017), 441–450. [41](#), [43](#), [148](#)
- [40] KAPAKU, R. K., RANKIN, B. A., AND GORE, J. P. Quantitative imaging of radiation from soot and carbon dioxide in a turbulent ethylene jet diffusion flame. *Combust. Flame* 162, 10 (apr 2015), 3704–3710. [36](#)

- [41] KAWAGOE, K. *Fire Behavior In Rooms*, report 27 ed. No. 27. Building Research Institute, Ministry Construction, Of, Tokyo, 1958. [21](#), [22](#), [25](#), [50](#), [144](#)
- [42] KIM, J.-H., AND LATTIMER, B. Y. Real-time probabilistic classification of fire and smoke using thermal imagery for intelligent firefighting robot. *Fire Saf. J.* 72 (feb 2015), 40–49. [41](#), [148](#)
- [43] KIM, J.-H., SUNG, Y., AND LATTIMER, B. Y. Bayesian Estimation based Real-Time Fire-Heading in Smoke-Filled Indoor Environments Using Thermal Imagery. IEEE International Conference on Robotics and Automation (ICRA), pp. 5231–5236. [41](#), [43](#)
- [44] KIM, W. H. DSP Embedded Early Fire Detection Method Using IR Thermal Video. *KSII Trans. Internet Inf. Syst.* 8, 10 (oct 2014), 3475–3489. [38](#), [43](#)
- [45] LAKHMI C. JAIN, AND LIM, C. P. *Handbook on decision making*. Springer, 2010. [40](#), [43](#)
- [46] LAMBERT, K. Backdraft: fire science and firefighting, a literature review. Tech. rep. [12](#), [145](#)
- [47] LEE, E. W., LEE, Y., LIM, C., AND TANG, C. Application of a noisy data classification technique to determine the occurrence of flashover in compartment fires. *Adv. Eng. Informatics* 20, 2 (apr 2006), 213–222. [39](#), [43](#), [148](#)
- [48] LEE, E. W. M. An incremental adaptive neural network model for online noisy data regression and its application to compartment fire studies. *Appl. Soft Comput.* 11, 1 (jan 2011), 827–836. [40](#), [43](#)
- [49] LEE, E. W. M., YUEN, R. K. K., LO, S. M., AND LAM, K. C. Probabilistic inference with maximum entropy for prediction of flashover in single compartment fire. *Adv. Eng. Informatics* (2001). [39](#), [43](#), [148](#)
- [50] LEE, E. W. M., YUEN, R. K. K., LO, S. M., LAM, K. C., AND YEOH, G. H. A novel artificial neural network fire model for predic-

tion of thermal interface location in single compartment fire. *Fire Saf. J.* 39 (2004), 67–87. [38](#), [40](#), [43](#), [148](#)

- [51] LEE, Y.-P., DELICHATSIOS, M. A., AND SILCOCK, G. Heat fluxes and flame heights in façades from fires in enclosures of varying geometry. In *Proc. Combust. Inst.* (jan 2007), vol. 31, pp. 2521–2528. [21](#)
- [52] MACKAY, D., BARBER, T., AND LEONARDI, E. CFD Model of a Specific Fire Scenario. *16th Australas. Fluid Mech. Conf.* (2007), 5. [29](#), [33](#), [50](#), [150](#)
- [53] MARKOV, A. A. Essai d’une recherche statistique sur le texte du roman “Eugene Onegin” illustrant la liaison des epreuve en chain (‘Example of a statistical investigation of the text of “Eugene Onegin” illustrating the dependence between samples in chain’). *Izvestia Imp. Akad. Nauk (Bulletin l’Academie Impériale des Sci. dé St.-Petersbourg)*, 7 (1913), 153–162. [92](#)
- [54] MARTIN, S. B., AND WIERSMA, S. J. An Experimental Study of Flashover Criteria for Compartment Fires. Tech. rep., Menlo Park, California, 1979. [21](#)
- [55] MCCAFFREY, B. J., QUINTIERE, J. G., AND HARKLEROAD, M. F. Estimating room temperatures and the likelihood of flashover using fire test data correlations. *Fire Technol.* 17, 2 (may 1981), 98–119. [22](#)
- [56] MCGRATTAN, K. B., BAUM, H. R., AND REHM, R. G. Large Eddy Simulations of Smoke Movement. Tech. rep., 1998. [54](#)
- [57] MERCI, B., AND BEJI, T. *Fluid Mechanics Aspects of Fire and Smoke Dynamics in Enclosures*, department ed. CRC Press/Balkema, Ghent, Belgium, 2016. [XVII](#), [XXIII](#), [8](#), [144](#), [148](#)
- [58] MEREL RUITER, M., AND JANA DOMROSE, M. Fatal residential fires in Europe. Tech. rep., Institute for Safety Fire Service Academy, 2018. [XXVII](#), [XXIX](#), [6](#), [139](#), [140](#)

- [59] MONGE., G. M'emoire sur la th'eorie des d'eblais et des remblais. In *Histoire de l'Acad'emie Royale des Sciences de Paris*. 666–704. [63](#)
- [60] NATIONAL FIRE PROTECTION ASSOCIATION. NFPA 921: Guidelines for Fire and Explosion Investigation, 2011. [XXVII](#), [XXIX](#), [3](#), [10](#), [11](#), [142](#), [143](#), [144](#), [147](#)
- [61] NEWALE, A. S., RANKIN, B. A., LALIT, H. U., GORE, J. P., AND MCDERMOTT, R. J. Quantitative infrared imaging of impinging turbulent buoyant diffusion flames. *Proc. Combust. Inst.* *35*, 3 (2015), 2647–2655. [36](#)
- [62] PARK, J.-W., OH, C. B., CHOI, B. I., AND HAN, Y. S. Computational visualization of the backdraft development process in a compartment. *J. Vis.* *18*, 1 (feb 2015), 25–29. [32](#), [33](#)
- [63] PARK, J.-W., OH, C. B., HAN, Y. S., AND DO, K. H. Computational study of backdraft dynamics and the effects of initial conditions in a compartment. *J. Mech. Sci. Technol.* *31*, 2 (feb 2017), 985–993. [32](#), [33](#)
- [64] PEACOCK, R. D., RENEKE, P. A., BUKOWSKI, R. W., AND BABRAUSKAS, V. Defining flashover for fire hazard calculations. *Fire Saf. J.* *32* (1999), 331–345. [21](#), [22](#), [25](#), [50](#)
- [65] RABINER, L. R. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. *Proc. IEEE* *77*, 2 (1989), 257–286. [95](#)
- [66] RANKIN, B. A., IHME, M., AND GORE, J. P. Model-based imaging of mid-infrared radiation from a turbulent nonpremixed jet flame and plume. In *8th U. S. Natl. Combust. Meet.* (apr 2013). [36](#)
- [67] RANKIN, B. A., IHME, M., AND GORE, J. P. Quantitative model-based imaging of mid-infrared radiation from a turbulent nonpremixed jet flame and plume. [34](#), [36](#)

- [68] STECKLER, K., BAUM, H., AND QUINTIERE, J. Fire induced flows through room openings—flow coefficients. In *Symp. Combust.* (jan 1985), vol. 20, pp. 1591–1600. [21](#), [28](#), [38](#)
- [69] SUDHEER, S., SAUMIL, D., AND PRABHU, S. Physical experiments and Fire Dynamics Simulator simulations on gasoline pool fires. *J. Fire Sci.* 31, 4 (jul 2013), 309–329. [33](#), [35](#)
- [70] TAKEDA, H., NAKAYA, I., AND AKITA, K. Experimental Study of Small Enclosure Fire with Liquid Fuel. In *Present. Second Jt. Meet. U.S.-Japan Nat. Resour. Panel Fire Res. Safety, Tokyo, Oct. 1976.* (1976). [20](#), [21](#)
- [71] THOMAS, P., BULLEN, M., QUINTIERE, J., AND MCCAFFREY, B. Flashover and instabilities in fire behavior. *Combust. Flame* 38 (jan 1980), 159–171. [21](#), [22](#), [30](#), [67](#)
- [72] THOMAS, P. H. THE FIRE RESISTANCE REQUIRED TO SURVIVE A BURN OUT. Tech. rep., 1970. [21](#)
- [73] THOMAS, P. H. Testing products and materials for their contribution to flashover in rooms. *Fire Mater.* 5, 3 (sep 1981), 103–111. [22](#)
- [74] THURESON, P. Eurific – Cone Calorimeter Test Results Project 4 of the Eurefic fire research programme. *SP Swedish Natl. Test. Res. Inst. Fire Technol.* (1991). [57](#), [69](#)
- [75] VANDECASTEELE, F., MERCI, B., JALALVAND, A., AND VERSTOCKT, S. Object localization in handheld thermal images for fire-ground understanding. In *SPIE 10214* (may 2017), P. Bison and D. Burleigh, Eds., p. 1021405. [2](#), [43](#), [145](#), [149](#)
- [76] VITERBI, A. J., AND ODENWALDER, J. P. Further Results on Optimal Decoding of Convolutional Codes. *IEEE Trans. Inf. Theory* 15, 6 (1969), 732–734. [95](#)
- [77] WATERMAN, T. E. Room flashover—Criteria and synthesis. *Fire Technol.* 4, 1 (feb 1968), 25–31. [20](#), [21](#)

- [78] WENG, W. Experimental study of back-draft in a compartment with openings of different geometries. *Combust. Flame* 132, 4 (mar 2003), 709–714. [21](#), [23](#), [25](#), [32](#)
- [79] WENG, W., AND FAN, W. Critical condition of backdraft in compartment fires: a reduced-scale experimental study. *J. Loss Prev. Process Ind.* 16, 1 (jan 2003), 19–26. [21](#), [23](#), [25](#), [32](#)
- [80] WICKSTRÖM, U., ANDERSON, J., AND SJÖSTRÖM, J. Measuring Incident Heat Flux and Adiabatic Surface Temperature with Plate Thermometers in Ambient and High Temperatures Measuring Incident Heat Flux and Adiabatic Surface Temperature with Plate Thermometers in Ambient and High Temperatures. [XIX](#), [74](#)
- [81] WU, C. L., AND CARVEL, R. An experimental study on backdraught: The dependence on temperature. *Fire Saf. J.* 91, February (jul 2017), 320–326. [21](#), [24](#), [25](#)
- [82] YEOH, G., YUEN, R., CHUENG, S., AND KWOK, W. On modelling combustion, radiation and soot processes in compartment fires. *Build. Environ.* 38, 6 (jun 2003), 771–785. [21](#), [23](#), [25](#), [26](#), [27](#), [33](#)
- [83] YEOH, G. H., YUEN, R. K. K., CHEN, D. H., AND KWOK, W. K. COMBUSTION AND HEAT TRANSFER IN COMPARTMENT FIRES. *Numer. Heat Transf. Part A Appl.* 42, 1-2 (jul 2002), 153–172. [21](#), [27](#), [33](#)
- [84] YEOH, G. H., YUEN, R. K. K., LO, S. M., AND CHEN, D. H. On numerical comparison of enclosure fire in a multi-compartment building. *Fire Saf. J.* 38 (2003), 85–94. [23](#), [25](#), [27](#), [33](#)
- [85] YUEN, A. C. Y., YEOH, G. H., ALEXANDER, B., AND COOK, M. Fire scene investigation of an arson fire incident using computational fluid dynamics based fire simulation. *Build. Simul.* 7, 5 (oct 2014), 477–487. [30](#), [33](#), [50](#), [150](#)
- [86] YUEN, R. K., LEE, E. W., LO, S., AND YEOH, G. Prediction of temperature and velocity profiles in a single compartment fire by an

- improved neural network analysis. *Fire Saf. J.* 41, 6 (sep 2006), 478–485. [40](#), [43](#), [148](#)
- [87] YUN, K., BUSTOS, J., AND LU, T. Predicting Rapid Fire Growth (Flashover) Using Conditional Generative Adversarial Networks. *Electron. Imaging 2018*, 9 (jan 2018), 127–1–127–4. [42](#), [43](#)
- [88] ZABETACIS, M. G. FLAMMABILITY CHARACTERISTICS OF COMBUSTIBLE GASES AND VAPORS. *Washington, U.S. Dept Inter. Bureu Mines Bulletin 6* (1965). [25](#)
- [89] ZHAO, G., BEJI, T., AND MERCI, B. Application of FDS to Under-Ventilated Enclosure Fires with External Flaming. *Fire Technol.* 52, 6 (nov 2016), 2117–2142. [28](#), [33](#), [50](#), [55](#), [150](#)

# Lista de Acrónimos

---

**VIF** flashover inducido por ventilación

**TC** Cámara de visión térmica

**AI** Inteligencia artificial

**ANN** Redes neuronales artificiales

**CNN** Redes neuronales convolucionales

**CFD** Simulación de fluidos computacional

**HRR** Tasa de liberación de calor

**LES** Técnica de simulación de grandes remolinos

**FDS** Fire Dynamics Simulator

**DNS** Simulación numérica directa

**JTFA** Análisis conjunto de tiempo-frecuencia

**PEmap** Mapeo probabilístico con máxima entropía

**PENN** red neuronal basado en la entropía probabilística

**OT** Teoría del transporte óptimo

**WD** Distancia Wasserstein

**HTI** Interfaz térmica

**HMM** Modelo oculto de Markov



Universitat d'Alacant  
Universidad de Alicante