

# TESIS DOCTORAL

AÑO 2019



## RECONOCIMIENTO DE EVENTOS MEDIANTE TEORÍA DE MARTINGALAS EN PLASMAS TERMONUCLEARES

D. TOMÁS CRUZ BARRIOS

PROGRAMA DE DOCTORADO EN INGENIERÍA DE SISTEMAS  
Y DE CONTROL

Directores:

Dr. D. SEBASTIÁN DORMIDO CANTO  
Dr. D. JESÚS ANTONIO VEGA SÁNCHEZ



*A Tomás y Valeria*



# Agradecimientos

---

Cierto es, que hasta que uno no concluye el trabajo de redactar una tesis doctoral y tiene la oportunidad de repasar todo lo que tuvo que realizar, no es realmente consciente del alto volumen de horas y esfuerzos que invirtió para su elaboración. Esta ardua tarea se hace imposible de abordar sin la guía, ayuda y aliento de las personas que te han acompañado en tan prolijo viaje. Todo esto hace que sea imprescindible que toda tesis doctoral disponga de una sección de agradecimientos. Tarea, la de los agradecimientos, nada sencilla, al menos para este que escribe, y posiblemente de las de más importancia en cualquier tesis doctoral que se precie de tal. Decía Don Quijote: *“Entre los pecados mayores que los hombres cometen, aunque algunos dicen que es la soberbia, yo digo que es el desagrado.”* Como quiera que yo no deseo caer en pecado capital agudizaré el ingenio y el lápiz (teclado en mi caso) para intentar agradecer como merecen a las personas que a continuación mencionaré.

Al primero que nombraré es a Jesús Vega al que he de agradecer todo el tiempo que me dedicó y lo mucho que me enseñó en este campo del que es, indudablemente, referencia para muchos. También su guía en los momentos difíciles y su buen humor que lo hacían más llevaderos, así como el haberme contagiado de su pasión por este campo de trabajo.

El siguiente agradecimiento es para Sebastián Dormido Canto por convencerme a enrolarme en esta aventura de realizar una tesis doctoral. Tarea esta que me ha permitido conocer que mis límites estaban más allá de donde inicialmente pensaba y que me han permitido llegar allí donde nunca pensé que llegaría. En resumen, por ver en mí lo que yo no vi. Gracias.

Gracias a mi madre, por los momentos de risas, confianzas y ayuda incondicional cuando más lo necesitaba. Gracias por todos tus esfuerzos para ayudarme a salir adelante cuando lo necesité y afrontar el futuro con optimismo.

Gracias también a mi padre, por inculcarme su entusiasmo en cada actividad que realizo y sus ganas de vivir y disfrutar cada momento de la vida. Aunque no estés te siento muy cerca. Gracias.

A mis hermanos y amigos por su apoyo en los momentos más difíciles. Por hacer

que las celebraciones sean más alegres y las penas menos tristes. En especial a mi amigo Julián, mi otro hermano, por estar siempre ahí de forma desinteresada y generosa y hacer que mi vida sea más divertida y llevadera.

Por último, y no menos importante, a mi hijos, Tomás y Valeria por soportar mis ausencias y por vuestro cariño incondicional que tanto me reconforta. Por ayudarme a querer ser cada día un poquito mejor para hacer lo mejor posible el trabajo más complicado e ilusionante que hice nunca, ser padre.

*Tomás Cruz Barrios*

*Sevilla, 2019*

# Resumen

---

Los plasmas de fusión son sistemas físicos regidos por complejas interacciones altamente no lineales y que necesitan diagnosticarse de la mejor manera posible. La base de datos de cualquier dispositivo experimental de fusión actual se compone de millones de señales. La mayoría de estas señales son de evolución temporal, con un número de muestras entre 10.000 y varios millones. Por ejemplo, en el tokamak JET (con una duración de descarga de 40 s), se han realizado más de 90.000 disparos y el número de señales que se adquieren en cada descarga puede ser superior a 10.000. En la actualidad, el tamaño de la base de datos de JET es de 100 Terabytes y su tendencia de crecimiento refleja que la cantidad de datos adquiridos se duplica cada dos años. En ITER se espera que se produzcan Terabytes de datos por descarga, lo que significa producir Petabytes de datos por año. Por tanto, es un requisito totalmente necesario la inclusión de sistemas automáticos que permitan un tratamiento eficiente y global de las bases de datos de fusión.

Por lo expuesto y dada la enorme cantidad de información a tratar, las técnicas de aprendizaje automático (*Machine Learning*) resultan de gran ayuda en el análisis de señales. En particular, las técnicas de reconocimiento de cambios en flujos de datos son útiles tanto en análisis en tiempo real como en diferido (off-line). El trabajo de investigación de la presente tesis consiste en el desarrollo y estudio de un sistema automático, basado en martingalas, para la detección de eventos en plasmas termonucleares. El sistema automático de reconocimiento es general y no depende de un evento particular o representación específica (formas de onda, imágenes o señales multidimensionales). Se han obtenidos resultados positivos con la detección de eventos en perfiles de bolometría del TJ-II e imágenes de JET.

## Lista de palabras clave:

Detección de cambios, tiempo-real, aprendizaje automático, plasmas de fusión nuclear, martingalas, predictores conformales.



# Abstract

---

Fusion plasmas are complex physical systems governed by highly nonlinear interactions and need to be diagnosed in the best possible way. The database of any current device consists of millions of signals. Most of them are temporal evolution signal, with a number of samples between 10,000 to several million. For example, in the JET tokamak (whose discharge is 40 s long), there have been over 90,000 shots and the number of signals acquired in each discharge may be greater than 10,000. At present, the size of the JET database is 100 Terabytes and its growth trend shows that the amount of acquired data is doubling every two years. ITER will produce Terabytes of data per discharge, which means producing Petabytes of data per year. Therefore, it is necessary to include automated systems that carry out an efficient and comprehensive treatment of fusion databases.

For these reasons, given the enormous amount of information, automated learning techniques are very helpful in analyzing signals. In particular, techniques for recognizing changes in data streaming are useful in both real-time and off-line analysis. This thesis consists of the development and study of an automatic system, based on martingales, for the detection of events in thermonuclear plasmas. The automatic event recognition system is absolutely general and it does not depend on either the particular event to detect or the specific data representation (waveforms, images or multidimensional signals). The developed approach provides good results for change detection in TJ-II bolometer profiles and JET images.

## Key words:

Change detection, real-time, machine learning, fusión plasmas, martingales, conformal predictors.



# Índice

---

AGRADECIMIENTOS.....	V
RESUMEN .....	VII
ABSTRACT .....	IX
ÍNDICE .....	XI
ÍNDICE DE FIGURAS .....	XV
ÍNDICE DE TABLAS.....	XIX
ABREVIATURAS.....	XXI
<b>1 INTRODUCCIÓN.....</b>	<b>1</b>
1.1. NECESIDADES ENERGÉTICAS MUNDIALES Y EL PROBLEMA DEL CAMBIO CLIMÁTICO...1	
1.2. SOLUCIONES ENERGÉTICAS VIABLES: RENOVABLES Y ENERGÍA NUCLEAR .....	2
1.3. BIG DATA EN CIENCIA Y TECNOLOGÍA.....	4
1.3.1. <i>El fenómeno de los datos masivos</i> .....	4
1.3.2. <i>Infraestructuras: escalando mediante sistemas distribuidos y paralelos</i> .....	6
1.3.2.1. Paralelismo Hardware .....	7
1.3.2.2. CPUs multinucleo .....	10
1.3.2.3. Memorias Flash.....	10
1.3.2.4. Sistemas de gestión de flujos de datos.....	11
1.3.2.5. Computación en la nube.....	12
1.3.2.6. MapReduce.....	14
1.3.2.7. Sistemas y lenguajes de programación paralela.....	15
1.3.3. <i>El cuarto paradigma: eScience</i> .....	15
1.3.4. <i>eScience aplicada al estudio de la fusión nuclear</i> .....	16
1.4. OBJETIVOS.....	16
1.5. ESTRUCTURA DE LA TESIS.....	18
<b>2. FUSIÓN NUCLEAR.....</b>	<b>19</b>
2.1. REACCIONES NUCLEARES .....	19
2.2. PLASMAS DE FUSIÓN .....	22
2.3. CONDICIONES NECESARIAS PARA LAS REACCIONES DE FUSIÓN .....	23
2.4. CONFINAMIENTO DEL PLASMA .....	24
2.5. CONFINAMIENTO MAGNÉTICO .....	26
2.5.1. <i>Stellarator</i> .....	26
2.5.2. <i>Tokamak</i> .....	28

2.6. DISRUPCIONES.....	30
2.6.1. <i>Causas de las disrupciones</i> .....	32
2.6.1.1. Disrupciones de límite de densidad .....	33
2.6.1.2. Disrupciones low-q.....	34
2.6.1.3. Límite de beta o límite de disrupción del modo <i>ballooning</i> .....	34
2.6.2. <i>Fases de las disrupciones</i> .....	34
2.7. TJ-II Y JET.....	36
2.8. ITER.....	38
2.9. DEMO.....	40
2.10. DIAGNOSIS.....	42
<b>3. FUNDAMENTOS TEÓRICOS Y ESTADO DEL ARTE.....</b>	<b>45</b>
3.1. DEFINICIÓN DE EVENTOS.....	45
3.2. RETOS EN LA DETECCIÓN DE EVENTOS .....	45
3.3. DATOS DE ENTRADA.....	46
3.4. TIPOS DE ANOMALÍAS .....	47
3.5. ESTADO DEL ARTE.....	49
3.6. MÉTODOS DE DETECCIÓN DE ANÓMALOS PARA DATOS DE BAJA DIMENSIONALI-	
DAD.....	49
3.6.1. <i>Métodos de detección estadística</i> .....	49
3.6.1.1. Métodos paramétricos .....	50
3.6.1.2. Métodos no paramétricos.....	50
3.6.1.3. Ventajas y desventajas de los métodos estadísticos .....	50
3.6.2. <i>Métodos basados en distancias</i> .....	52
3.6.2.1. Vecindad local .....	52
3.6.2.2. Distancia kNN .....	52
3.6.2.3. Ventajas y desventajas de los métodos basados en distancias .....	53
3.6.3. <i>Métodos basados en densidad</i> .....	53
3.6.3.1. LOF (Local Outlier Factor).....	53
3.6.3.2. COF (Connectivity-base Outlier Factor) .....	55
3.6.3.3. Ventajas y desventajas de los métodos basados en densidad.....	55
3.6.4. <i>Métodos basados en clustering</i> .....	56
3.6.4.1. Agrupación de clústeres.....	56
3.6.4.2. Agrupación jerárquica .....	57
3.6.4.3. Clustering basado en densidad .....	57
3.6.4.4. Clustering basado en cuadrícula (grid).....	57
3.6.4.5. Ventajas y desventajas de los métodos basados en clustering .....	58
3.7. MÉTODOS DE DETECCIÓN DE ANÓMALOS PARA DATOS DE ALTA	
DIMENSIONALIDAD .....	58
3.7.1. <i>Cubo disperso</i> .....	59
3.7.2. <i>Método basado en ejemplos</i> .....	59
3.7.3. <i>Detección de anómalos en subespacios</i> .....	59
3.7.4. <i>Detección de anómalos en subespacios para datos categóricos</i> .....	60
3.8. DETECCIÓN DE ANÓMALOS EN SUBESPACIOS DE ALTA DIMENSIONALIDAD .....	60
3.9. DETECCIÓN DE ANÓMALOS O EVENTOS EN FLUJOS DE DATOS.....	61
3.9.1. <i>Requerimientos de un algoritmo para la detección de eventos en flujos de datos</i> ....	61
3.10. DETECCIÓN DE CAMBIOS BASADO EN PREDICTORES CONFORMALES.....	63

3.11. PREDICCIONES INDUCTIVAS Y TRANSDUCTIVAS.....	64
3.12. APRENDIZAJE ON-LINE Y OFFLINE .....	65
3.13. PREDICTORES CONFORMALES .....	66
3.13.1. <i>Introducción</i> .....	66
3.13.2. <i>Medida de no conformidad</i> .....	67
3.13.3. <i>Medidas de extrañeza</i> .....	68
3.13.3.1. <i>k-NN: k vecinos más cercanos</i> .....	68
3.13.3.2. <i>SVM: Máquinas de vector soporte</i> .....	69
3.13.3.3. <i>Modelos de clúster</i> .....	71
3.13.3.4. <i>Modelos de regresión</i> .....	71
3.13.4. <i>Cálculo On-Line de p-valores</i> .....	71
3.14. TEST DE INTERCAMBIABILIDAD ON-LINE.....	72
3.14.1. <i>Conceptos de aleatoriedad e intercambiabilidad</i> .....	72
3.14.2. <i>Martingalas</i> .....	73
3.14.3. <i>Supermartingalas aleatorias e intercambiables</i> .....	73
3.14.4. <i>Martingalas intercambiables aleatorias</i> .....	74
3.14.5. <i>Martingalas basadas en p-valores</i> .....	74
3.14.5.1. <i>Randomized Power Martingale</i> .....	76
3.14.5.2. <i>Simple Mixture Martingale</i> .....	76
3.14.5.3. <i>Plug-In Martingale</i> .....	77
3.15. TEST DE MARTINGALAS PARA LA DETECCIÓN DE CAMBIOS.....	82
3.15.1. <i>Test de hipótesis basado en la regla de máxima desigualdad de Doob</i> .....	82
3.15.2. <i>Test de hipótesis basado en la regla de desigualdad de Hoeffding-Azuma</i> .....	83
3.15.3. <i>Algoritmo para el test de martingalas</i> .....	85
3.15.4. <i>Rendimiento del test de martingala</i> .....	88
3.16. TEST DE MÚLTIPLES MARTINGALAS UTILIZANDO MULTIVISTAS.....	89
<b>4. APLICACIONES.....</b>	<b>91</b>
4.1. INTRODUCCIÓN .....	91
4.2. DETECCIÓN DE CAMBIOS EN PERFILES.....	91
4.2.1. <i>Descripción del problema y solución conceptual</i> .....	96
4.2.2. <i>Resultados</i> .....	97
4.2.3. <i>Implementación de Randon Power Martingale en una FPGA para la detección de eventos en tiempo real</i> .....	100
4.3. IDENTIFICACIÓN DE CAMBIOS EN DIAGNÓSTICOS DE IMAGEN DE DISPOSITIVOS DE FUSIÓN .....	101
4.3.1. <i>Sistemas de cámaras de JET</i> .....	102
4.3.2. <i>UMEL (Universal Multi-Event Locator)</i> .....	102
4.3.2.1. <i>SVM para regresión</i> .....	103
4.3.2.1.1. <i>Kernels para estimar funciones de valor real</i> .....	104
4.3.2.1.2. <i>Zona e-insensible</i> .....	105
4.3.2.1.3. <i>Regularización del parámetro C</i> .....	105
4.3.2.1.4. <i>Vectores Soporte</i> .....	106
4.3.2.2. <i>Conclusiones de UMEL</i> .....	106
4.3.3. <i>Tratamiento de imágenes con UMEL y el Test de Martingalas</i> .....	108

4.3.3.1. UMEL .....	109
4.3.3.2. Test de Martingalas (TM).....	110
4.3.3.2.1. Video kl7_70231 .....	112
4.3.3.2.2. Video kl8_69331 .....	113
4.3.3.2.3. Video kl8_69481 .....	113
4.3.3.2.4. Video kl8_69787 .....	114
4.3.3.3. Conclusiones .....	114
4.4. DETECCIÓN DE DISRUPCIONES: SPAD.....	115
4.4.1. SPAD ( <i>Single signal Predictor based on Anomaly Detection</i> ) .....	116
4.4.1.1. Generación del vector de características .....	116
4.4.1.2. Distancia de Mahalanobis y criterio de anomalía.....	117
4.4.2. <i>El test de martingala como criterio de anomalía</i> .....	119
4.4.2.1. Pruebas realizadas y resultados.....	119
<b>5. CONCLUSIONES Y LÍNEAS FUTURAS .....</b>	<b>121</b>
5.1. CONCLUSIONES .....	121
5.2. LÍNEAS FUTURAS .....	122
<b>6. BIBLIOGRAFÍA .....</b>	<b>127</b>
<b>ANEXO A – TEST DE MARTINGALAS.....</b>	<b>143</b>

# Índice de Figuras

---

<b>Figura 1-1:</b> Arquitectura de la plataforma PureData System for Analytics de IBM .....	9
<b>Figura 1-2:</b> Ejemplo de arquitectura de la GPU de la tarjeta gráfica de Nvidia GeForce 8800 GTX .....	9
<b>Figura 1-3:</b> Arquitectura abstracta de referencia para un sistema de gestión de flujos de datos (DSMS) [16] .....	11
<b>Figura 1-4:</b> Arquitectura básica de servicios en la nube y software como servicio (SaaS) [17] .....	12
<b>Figura 1-5:</b> Visión de conjunto de ejecución de MapReduce [22] .....	14
<b>Figura 2-1:</b> Gráfico de las energías de enlace nuclear según la masa atómica. El rendimiento para la fusión es mucho mayor que para la fisión .....	20
<b>Figura 2-2:</b> Representación esquemática de la reacción de fusión D-T. Un núcleo de helio y un neutrón, liberándose una energía de 17,58 MeV .....	21
<b>Figura 2-3:</b> Secciones eficaces de las reacciones nucleares D-T, D-D, D-He <sup>3</sup> .....	22
<b>Figura 2-4:</b> Diferentes tipos de plasmas en astrofísica, física solar y física de estado sólido, fusión nuclear, y para aplicaciones técnicas en un diagrama de temperatura de electrones frente a densidad de electrones. La línea verde denota la limitación de los plasmas no relativistas, los plasmas degenerados y no ideales se colocan directamente desde la línea azul y roja, respectivamente .....	23
<b>Figura 2-5:</b> Estrategia de NIF (National Ignition Facility) para fusión .....	25
<b>Figura 2-6:</b> Visión esquemática de un reactor de fusión basado en confinamiento magnético: (A) Cámara de vacío; (B) Plasma; (C) Radiación del plasma; (D) Manto; (E) Producción de electricidad [38] .....	26
<b>Figura 2-7:</b> Stellarator TJ-II. El plasma se representa en color fucsia. Se pueden apreciar las ventanas de observación para la diagnosis del plasma .....	28

<b>Figura 2-8:</b> Representación esquemática de un Tokamak. El plasma se presenta en color rosado .....	28
<b>Figura 2-9:</b> Sección transversal de un plasma de fusión tórico y sus principales características geométricas.....	30
<b>Figura 2-10:</b> Evolución en el tiempo de (a) corriente de plasma (rojo), amplitud de modo bloqueado (negro), (b) beta poloidal (azul), $q_{95}$ (rosa), c) densidad integrada de línea medida por interferómetro, d) potencia de entrada total (azul) y potencia total radiada medida con bolómetro (rojo) para la disrupción JET-ILW N° 82569 [46] .....	31
<b>Figura 2-11:</b> El diagrama de Hugill .....	33
<b>Figura 2-12:</b> Secuencia de una disrupción. $A_r/D_2$ inyección, $p_{DMV} = 3,6\text{MPa}$ ....	35
<b>Figura 2-13:</b> Fotografía de JET ITER-Like Wall (ILW). El sombreado de colores indica el material de cada componente [62] .....	38
<b>Figura 2-14:</b> Recreación de ITER. Fuente: Jamison Daniel, Oak Ridge Leadership Computing Facility.....	40
<b>Figura 2-15:</b> Aunque el calendario, las especificaciones técnicas y el nivel de determinación varían de un miembro a otro, el objetivo es el mismo para todos: construir la máquina que demuestre la obtención de electricidad de fusión a escala industrial para 2050. Ejemplo conceptual de una futura máquina DEMO [67].....	41
<b>Figura 2-16:</b> Localización y representación esquemática de los principales diagnósticos del stellarator TJ-II [68].....	42
<b>Figura 2-17:</b> Localización y representación esquemática de los principales diagnósticos del tokamak JET.....	43
<b>Figura 3-1:</b> Un ejemplo de anómalos en un conjunto de datos bidimensional. $B_1$ y $B_2$ representan valores anómalos .....	47
<b>Figura 3-2:</b> Ejemplo de anómalos $P_1$ y $P_2$ en un conjunto de datos 2-D.....	55
<b>Figura 3-3:</b> Predicción inductiva y transductiva.....	64
<b>Figura 3-4:</b> (a) curva de decisión generada por el clasificador mediante la función de kernel de base radial ( $\sigma = 2$ ) y $C = 2$ . (b) curva de decisión generada por el clasificador mediante la función de kernel polinomial ( $\beta = 1, n = 3$ ) y $C = 2$ . Los vectores soporte están rodeados con un círculo. Las líneas de punto indican el margen [133] .....	70

<b>Figura 3-5:</b> Valores de función de apuesta que se utilizan para calcular Randomized Power y Simple Mixture Martingale.....	75
<b>Figura 3-6:</b> Cuatro estimaciones del kernel de densidad utilizando $n = 100$ y variables generadas aleatoriamente siguiendo distribución normal. Obsérvese que cuanto menor es el valor de $h$ , la estimación es menos precisa.....	79
<b>Figura 3-7:</b> Gráficos de varios kernels que pueden utilizarse para estimar la función de densidad. Test de martingalas para la detección de cambios.....	81
<b>Figura 3-8:</b> Comparación del límite superior de la probabilidad de la diferencia de martingalas para algunos valores $t = 0.92$ , y el límite superior de probabilidad fija para el valor de martingala cuando $\lambda = 20$ en una secuencia de datos que consta de 100.000 puntos de datos. Tener un límite superior para la desigualdad máxima de Doob que coincida con el límite superior para un valor $t$ particular (por ejemplo, 3 - 4) para una $n$ pequeña ( $<5000$ ), $\lambda$ tiene que ser muy grande ....	85
<b>Figura 3-9:</b> Datos de entrada de 2-D .....	87
<b>Figura 3-10:</b> En el gráfico puede verse el valor de $M$ para el conjunto de prueba del ejemplo de la Figura 3-9. El valor de $\lambda = 20$ y $\varepsilon = 0,85$ .....	87
<b>Figura 3-11:</b> Valores de los diferentes $p$ -valores que se calculan en el ejemplo...	88
<b>Figura 4-1:</b> Simulación de cambios en flujos de datos. Los cambios mostrados son: (a) cambio suave a una amplitud mayor; (b) mayor ancho; (c) Perfiles con ruido .....	92
<b>Figura 4-2:</b> Ejemplos de efectos de la variable $\alpha_1$ de la Ec. 4-1 .....	93
<b>Figura 4-3:</b> Ejemplos de efectos de la variable $\alpha_2$ de la Ec. 4-1 .....	93
<b>Figura 4-4:</b> Ejemplos de efectos de la variable $A_0$ en la Ec. 4-1 .....	94
<b>Figura 4-5:</b> Ejemplos de efectos de ruido simulado para la Ec. 4-1 .....	94
<b>Figura 4-6:</b> Ejemplos de suavizado para los casos de la Figura 4-5 con $\alpha_1 = 4$ , $\alpha_2 = 4$ .....	95
<b>Figura 4-7:</b> Simulación de líneas de contorno de emisión del plasma con diferentes niveles de fluctuación.....	95
<b>Figura 4-8:</b> Evolución temporal de perfiles de bolometría. Perfiles de bolometría del stellarator TJ-II (descarga 21319) .....	96
<b>Figura 4-9:</b> (a) Idealmente, el vector de características debería ser seleccionado de	

forma que los dos estados sean separables en el espacio de características. (b) Los datos son leídos de forma secuencial, uno a uno .....	97
<b>Figura 4-10:</b> Ejemplo de función de SVR; $C=20$ , $s=0,5$ , $e$ -valor = 0,9 .....	108
<b>Figura 4-11:</b> Fotogramas de los 4 videos que se utilizan en el estudio .....	109
<b>Figura 4-12:</b> Ejemplo tratado con UMEL en el que pueden verse los SVs y ESVs .....	110
<b>Figura 4-13:</b> TM para el video kl7_70231. RPM para $\lambda = 50$ y $\varepsilon = 0,95$ .....	111
<b>Figura 4-14:</b> Fotogramas desde el 133 al 168 para el video kl7_70231 .....	112
<b>Figura 4-15:</b> Fotogramas desde el 1.485 al 1.520 para el video kl8_69331 .....	113
<b>Figura 4-16:</b> Fotogramas desde el 203 al 238 para el video kl8_69481 .....	113
<b>Figura 4-17:</b> Fotogramas desde el 796 al 831 para el video kl8_69787 .....	114
<b>Figura 4-18:</b> Explicación de muestras de señales de empaquetamiento en ventanas deslizantes. Ejemplo de la distribución de muestras en ventanas de 32 elementos con deslizamiento de 2 ms .....	116
<b>Figura 4-19:</b> Representación de los dos coeficientes de aproximación de la transformación Haar Wavelet para la descarga disruptiva (a) y no disruptiva (b) como vector de característica en un espacio bidimensional .....	117
<b>Figura 4-20:</b> Ejemplo de distancias Euclídea y Mahalanobis para el disparo 83175 de JET .....	118
<b>Figura 4-21:</b> Ejemplo de distancias de Mahalanobis para cargas disruptivas y no disruptivas. En el caso de la descarga disruptiva, las distancias de Mahalanobis se disparan momentos antes de que se produzca la interrupción .....	118
<b>Figura 5-1:</b> Arquitectura para la detección de estados críticos en sistemas físicos complejos [146] .....	122

# Índice de Tablas

---

<b>Tabla 1-1:</b> Campos de la ciencia y la ingeniería impactados por datos masivos ..	6
<b>Tabla 1-2:</b> Los 10 mayores obstáculos y oportunidades de crecimiento de los servicios en la nube según [17] .....	13
<b>Tabla 2-1:</b> Características de diferentes dispositivos tokamaks [41].....	29
<b>Tabla 2-2:</b> Descripción del significado de las variables y los parámetros físicos utilizados .....	32
<b>Tabla 3-1:</b> Resumen de los principales métodos de detección de anomalos según [79].....	63
<b>Tabla 3-2:</b> Ejemplos de Kernels para la estimación de la densidad .....	80
<b>Tabla 4-1:</b> Perfiles de la Figura 4-1 (a) que han sido distorsionados con ruido Gaussiano $N(0, 0,1)$ y la amplitud ha sido incrementada un 10%.....	98
<b>Tabla 4-2:</b> Perfiles de la Figura 4-1 (b) que han sido distorsionados con ruido Gaussiano $N(0, 0,1)$ y el ancho del perfil a media altura se ha incrementado en un 10%.....	98
<b>Tabla 4-3:</b> Perfiles de la Figura 4-1 (c) misma altura pero diferente ruido Gaussiano $N(0,03, 0,1)$ .....	98
<b>Tabla 4-4:</b> Fluctuaciones de emisividad de plasma antes / después de la transición sigue las distribuciones $N(0, 0,015)$ / $N(0, 0,020)$ respectivamente .....	99
<b>Tabla 4-5:</b> Resultado Final UMEL .....	110
<b>Tabla 4-6:</b> Tiempos de ejecución para $\lambda = 100$ ; $\varepsilon = 0,95$ .....	112
<b>Tabla 4-7:</b> Resultados para video kl7_70231 .....	112
<b>Tabla 4-8:</b> Resultados para video kl8_69331 .....	113
<b>Tabla 4-9:</b> Resultados para video kl8_69481 .....	114

**Tabla 4-10:** Resultados para video kl8\_69787 .....114

**Tabla 4-11:** Resultado detección de interrupciones en curva de salida de SPAD119

# Abreviaturas

---

<b>AMISE</b>	<b>A</b> symtotic <b>M</b> ean <b>I</b> ntegrated <b>S</b> quared <b>E</b> rror
<b>API</b>	<b>A</b> pplication <b>P</b> rogramming <b>I</b> nterface
<b>AWS</b>	<b>A</b> mazo <b>n</b> <b>W</b> eb <b>S</b> ervices
<b>CBRNe</b>	<b>C</b> hemical, <b>B</b> iological, <b>R</b> adiological, <b>N</b> uclear, <b>e</b> nhan <b>c</b> ed improvised explosive devices
<b>CFC</b>	<b>C</b> arbono reforzado con <b>F</b> ibra de <b>C</b> arbono
<b>CIEMAT</b>	<b>C</b> entro de <b>I</b> vestigaciones <b>E</b> nergéticas, <b>M</b> edioambientales y <b>T</b> ecnológicas
<b>CODAC</b>	<b>C</b> ontrol, <b>D</b> ata <b>A</b> ccess and <b>C</b> ommunication
<b>CLARA</b>	<b>C</b> lustering <b>L</b> arge <b>A</b> pplications
<b>CLARANS</b>	<b>C</b> lustering <b>L</b> arge <b>A</b> pplications based on <b>R</b> andomized Search
<b>COF</b>	<b>C</b> onnectivity-base <b>O</b> utlier <b>F</b> actor
<b>CPU</b>	<b>C</b> entral <b>P</b> rocessing <b>U</b> nit
<b>CQL</b>	<b>C</b> ontextual <b>Q</b> uery <b>L</b> anguage
<b>CUDA</b>	<b>C</b> ompute <b>U</b> nified <b>D</b> evice <b>A</b> rchitecture
<b>CURE</b>	<b>C</b> lustering <b>U</b> sing <b>R</b> epresentative
<b>DBSCAN</b>	<b>D</b> ensity- <b>B</b> ased <b>S</b> patial <b>C</b> lustering of <b>A</b> pplications with <b>N</b> oise
<b>DClust</b>	<b>D</b> ynamical <b>C</b> lustering
<b>DENCLUE</b>	<b>D</b> ensity- <b>B</b> ased <b>C</b> lustering with <b>C</b> onstrains
<b>DSMS</b>	<b>D</b> ata <b>S</b> tream <b>M</b> anagement <b>S</b> ystem
<b>EC2</b>	<b>E</b> lastic <b>C</b> ompute <b>C</b> loud
<b>ELM</b>	<b>E</b> dge <b>L</b> ocalized <b>M</b> ode
<b>ESV</b>	<b>E</b> xternal <b>S</b> upport <b>V</b> ector
<b>ER</b>	<b>E</b> vento <b>R</b> elevante
<b>FAR</b>	<b>F</b> alse <b>A</b> larm <b>R</b> ate
<b>fMRI</b>	<b>f</b> unctional <b>M</b> agnetic <b>R</b> esonance <b>I</b> maging
<b>FPGA</b>	<b>F</b> ield <b>P</b> rogrammable <b>G</b> ate <b>A</b> rray
<b>GPU</b>	<b>G</b> raphics <b>P</b> rocessing <b>U</b> nit

<b>Grid-ODF</b>	<b>Grid Outlying Degree Factor</b>
<b>HBP</b>	<b>Human Brain Project</b>
<b>HighDOD</b>	<b>High-Dimension Outlying subspace Detection</b>
<b>IEA</b>	<b>Internacional Energy Agency</b>
<b>ILW</b>	<b>ITER-Like Wall</b>
<b>I/O</b>	<b>Input / Ouput</b>
<b>IoT</b>	<b>Internet of Thing</b>
<b>ISV</b>	<b>Internal Support Vector</b>
<b>ITER</b>	<b>International Thermonuclear Experimental Reactor</b>
<b>JET</b>	<b>Joint European Torus</b>
<b>kNN</b>	<b>k-Nearest Neighbors</b>
<b>KSTAR</b>	<b>Korean Superconduction Tokamak Advanced Research</b>
<b>LHC</b>	<b>Large Hadron Collider</b>
<b>LM</b>	<b>Locked Mode</b>
<b>LOF</b>	<b>Local Outlier Factor</b>
<b>LSST</b>	<b>Large Synoptic Survey Telescope</b>
<b>MARFE</b>	<b>Multifaceted Asymmetric Radiation From the Edge</b>
<b>MAST-U</b>	<b>Mega Amp Spherical Tokamak Upgrade</b>
<b>MHD</b>	<b>MagnetoHidroDinámica</b>
<b>MPI</b>	<b>Message Passing Interface</b>
<b>MST</b>	<b>Minimum Spanning Tree</b>
<b>MTCA</b>	<b>Micro Telecommunications Computing Architecture</b>
<b>Mtpe</b>	<b>Millones de toneladas de petróleo equivalente</b>
<b>NIF</b>	<b>National Ignition Facility</b>
<b>NRR</b>	<b>Normal Reference Rule</b>
<b>OECD</b>	<b>Organisation for Economic Co-operation and Development</b>
<b>OpenCL</b>	<b>Open Computing Language</b>
<b>ORNL</b>	<b>Oak Ridge National Laboratory</b>
<b>PAM</b>	<b>Partitioning Around Medoids</b>
<b>PBOD</b>	<b>Predictor Based on Outlier Detection</b>
<b>pdf</b>	<b>Probability density function</b>
<b>PIM</b>	<b>Plug-In Martingale</b>
<b>PSM</b>	<b>Patrón de Señal Múltiple</b>
<b>PVM</b>	<b>Parallel Virtual Machine</b>
<b>PXI</b>	<b>PCI eXtensions for Instrumentation</b>
<b>PXIe</b>	<b>PCI eXtensions for Instrumentation express</b>

<b>RAM</b>	<b>R</b> andom <b>A</b> ccess <b>M</b> emory
<b>RMI</b>	<b>R</b> emote <b>M</b> ethod <b>I</b> nvocation
<b>RPM</b>	<b>R</b> andomized <b>P</b> ower <b>M</b> artingale
<b>S3</b>	<b>S</b> imple <b>S</b> torage <b>S</b> ervice
<b>SaaS</b>	<b>S</b> oftware as a <b>S</b> ervice
<b>SBN-path</b>	<b>S</b> et- <b>B</b> ased <b>N</b> earest <b>p</b> ath
<b>SBN-trail</b>	<b>S</b> et- <b>B</b> ased <b>N</b> earest <b>t</b> rail
<b>SC</b>	<b>S</b> istema de <b>C</b> ontrol
<b>SC&amp;I</b>	<b>S</b> istema de <b>C</b> ontrol <b>&amp;</b> <b>I</b> nstrumentación
<b>SMM</b>	<b>S</b> imple <b>M</b> ixture <b>M</b> artingale
<b>SOF</b>	<b>S</b> ubspace <b>O</b> utlying <b>F</b> actor
<b>SPAD</b>	<b>S</b> ingle signal <b>P</b> redictor based on <b>A</b> nomaly <b>D</b> etection
<b>SPRT</b>	<b>S</b> equential <b>P</b> robability <b>R</b> atio <b>T</b> est
<b>SQL</b>	<b>S</b> tructure <b>Q</b> uery <b>L</b> anguage
<b>STING</b>	<b>S</b> tatistical <b>I</b> nformation <b>G</b> rid-based method
<b>SVM</b>	<b>S</b> upport <b>V</b> ector <b>M</b> achine
<b>TCAM</b>	<b>T</b> ernary <b>C</b> ontent <b>A</b> dressable <b>M</b> emory
<b>TJ-II</b>	<b>T</b> okamak de la <b>J</b> unta <b>I</b> I
<b>TM</b>	<b>T</b> est de <b>M</b> artingala
<b>UMEL</b>	<b>U</b> niversal <b>M</b> ulti- <b>E</b> vent <b>L</b> ocator
<b>USD</b>	<b>U</b> nited <b>S</b> tates <b>D</b> ollar
<b>VLAN</b>	<b>V</b> irtual <b>L</b> ocal <b>A</b> rea <b>N</b> etwork
<b>VM</b>	<b>V</b> irtual <b>M</b> achine
<b>W7X</b>	<b>W</b> endelstein <b>7-X</b>

**Nota:** se ha intentado traducir, siempre que fuera posible, del inglés al español. En aquellos casos en los que se la traducción puede llevar a equívoco se ha mantenido el vocablo en inglés.



# 1 INTRODUCCIÓN

---

*“Toda la gloria proviene de atreverse a comenzar”*

*- Eugene F. Ware -*

## **1.1. Necesidades energéticas mundiales y el problema del cambio climático.**

La Agencia Internacional de la Energía (IEA), en su informe estadístico anual de 2013 [1], estima que, de seguir la tendencia actual, las necesidades de abastecimiento de energía para 2035 podrían llegar hasta 11.750 Mtpe (Millones de toneladas de petróleo equivalente). Bajo el escenario de referencia de la *IEA World Energy Outlook*, los combustibles fósiles seguirán dominando como fuente primaria de energía, representando el 77% de dicho incremento. El 90% de esta demanda vendrá de países no pertenecientes a la OECD (Organisation for Economic Co-operation and Development), liderados por China, India y Países de Oriente Medio.

Estas tendencias, son inviables en relación con el medio ambiente, la seguridad energética y el desarrollo económico. Muchos países y regiones serán más dependientes de las importaciones de petróleo, aunque los combustibles obtenidos de gas de esquisto pueden cubrir gran parte de las necesidades energéticas, tal y como se tiene previsto para el caso de EE.UU. El sector del transporte concentrará gran parte de este crecimiento de la demanda, donde la elasticidad del precio es baja, y los riesgos incrementarán la volatilidad del mercado. Se producirá un rápido incremento de las emisiones de CO<sub>2</sub>, como consecuencia del aumento del consumo de combustibles fósiles, alcanzando 37.037 Mt en 2035, lo que incrementará la temperatura global 3,6°C. Asimismo, se producirá una subida del precio de los combustibles fósiles. Por ejemplo, se asume que los precios del petróleo llegarán a 128 USD (United States Dollar) por barril (en precios del 2002) para 2035.

Por otro lado, los acontecimientos de Fukushima, tras el terremoto de Japón de 2011, han puesto de nuevo en entredicho la seguridad y viabilidad económica de las instalaciones nucleares de fisión nuclear y su posible contribución a la seguridad del suministro, estabilidad de precios de la energía y disminución de gases de efecto invernadero. Por lo que el escenario anteriormente descrito puede ser aún más desfavorable.

Tanto productores como consumidores de energía se enfrentan a la urgente necesidad de ir a sistemas globales de energía más sostenibles.

## **1.2. Soluciones energéticas viables: Renovables y Energía nuclear**

En cuanto a las soluciones energéticas viables, se destacan dos: las energías renovables y la energía nuclear. Las energías renovables son en general bien aceptadas por la sociedad al no plantear aparentemente riesgos para los trabajadores y ser consideradas amigables con el medioambiente. A pesar de ello, la base para la construcción de paneles solares, por ejemplo, para la producción de energía fotovoltaica es el silicio (basado en el procesado de la sílice), cuya extracción es altamente costosa. Los molinos para la producción de energía eólica son menos rentables que otras instalaciones tradicionales, su instalación suele ser poco agradable a la vista y empieza a no estar claro que no tengan un impacto medioambiental. Además, no garantizan la seguridad del suministro ya que su producción está sujeta a fenómenos de la naturaleza que no se pueden controlar (la energía eólica depende de la velocidad del viento, mientras que la solar, térmica y fotovoltaica, de las horas de sol disponibles anualmente, y la minihidráulica del agua embalsada, etc.).

Otra solución es la energía nuclear que se presenta como una solución viable ya que puede producir grandes cantidades de energía. Esta puede ser generada mediante procesos de fisión nuclear, en las que se dividen núcleos de alto número másico, o de fusión nuclear, donde se juntan núcleos atómicos ligeros. La energía producida mediante fisión, descubierta en 1939 por los investigadores alemanes Hahn y Strassmann, se genera como una reacción en cadena. Este tipo de reacciones, hoy en día, pueden ser controladas con seguridad. Siendo sus principales ventajas las siguientes:

1. Garantiza el abastecimiento eléctrico.
2. Frena las emisiones contaminantes de  $CO_2$ .
3. Reduce la dependencia energética exterior.
4. Produce electricidad de forma constante con precios estables y predecibles.

Es por ello por lo que es considerada una parte muy importante en la generación de energía eléctrica en el mundo, actualmente existen 448 reactores nucleares en operación comercial y otros 57 en construcción, que generan aproximadamente

el 35% de la energía eléctrica consumida. Las centrales nucleares están instaladas principalmente en los países desarrollados, y dentro de la Unión Europea se encuentran en operación 148 reactores nucleares que proporcionan, aproximadamente, el 34% de la electricidad consumida por los Estados Miembros. Sin embargo, la extracción, enriquecimiento y utilización de materiales de alto peso atómico, como puede ser el uranio, para los procesos de fisión nuclear generan residuos radioactivos que tardan miles de años en perder su toxicidad para el medioambiente. La gestión y almacenamiento de esta basura radiactiva plantea además importantes retos técnicos y económicos. Todo ello genera un fuerte rechazo a este tipo de energías por parte de la población que, tal y como se ha comentado con anterioridad, ponen en entredicho el desarrollo futuro de este tipo de energía.

Otra forma de conseguir energía nuclear sería mediante la fusión termonuclear, aunque para esta solución todavía existen barreras que deben soslayarse, tales como la complejidad tecnológica de los dispositivos de fusión. El reto de la fusión consiste en reproducir en la Tierra, las reacciones que se producen en las estrellas, donde se fusionan átomos de hidrógeno para generar energía en forma de calor y luz, mediante la construcción de reactores de fusión capaces de satisfacer una gran parte de la demanda energética del planeta en el medio plazo. El combustible requerido, está disponible en abundancia: el deuterio está presente en el agua de los océanos y los mares ( $30g/m^3$ ), y el tritio puede ser producido a partir del litio, en el mismo reactor, en lo que comúnmente se denomina *manto fértil*. El sistema es intrínsecamente seguro debido al hecho de que un reactor sólo contiene, en un momento dado, una cantidad de combustible suficiente para unos pocos segundos de operación, además, es respetuoso con el medio ambiente, ya que no se producen escapes contaminantes. Al seleccionar elementos con un bajo grado de actividad no será necesario almacenar durante cientos de años residuos altamente radiactivos.

El objetivo de la investigación internacional en el campo de la fusión es diseñar un prototipo de planta de energía de fusión que esté de acuerdo con las demandas de la sociedad actual: a saber, que sea seguro, fiable, sostenible y amigable con el medio ambiente y económicamente viable. En los últimos diez años, se han realizado importantes progresos científicos y tecnológicos que nos intentan acercar a este objetivo.

## 1.3. Big Data en ciencia y tecnología

### 1.3.1. El fenómeno de los datos masivos

Aunque se han recopilado datos desde el comienzo de la historia registrada -de hecho, los datos recopilados en la antigüedad proporcionan gran parte de la materia prima para la reconstrucción de la historia humana- la tasa de adquisición de datos ha aumentado en los últimos años. Las expectativas también han aumentado, con la esperanza de nuevos descubrimientos científicos basados en colecciones masivas de datos biológicos, físicos y sociales, y con las principales áreas de la economía centradas en las implicaciones comerciales de los datos masivos. De aquí en adelante se utilizará indistintamente Big Data y datos masivos para referirnos al mismo concepto.

Aunque es difícil caracterizar todas las diversas razones del rápido crecimiento de los datos, hay algunos factores que vale la pena señalar [2].

1. Muchas áreas de la ciencia están en posesión de teorías maduras que explican una amplia gama de fenómenos, por lo que las pruebas adicionales y la elaboración de estas teorías requieren investigar los fenómenos extremos. Estas investigaciones a menudo generan conjuntos de datos muy grandes. Un ejemplo es el mundo de la física de partículas, donde los datos masivos surgen de los nuevos aceleradores diseñados para probar aspectos del Modelo Estándar de física de partículas. Como ejemplo más significativo se tiene el Gran colisionador de hadrones (LHC – Large Hadron Collider) que genera 1 Petabyte por día, de los cuales tiene registrados permanentemente más de 200 Petabytes [3].
2. Gran cantidad de áreas de la ciencia y la ingeniería se han vuelto cada vez más exploratorias, con grandes conjuntos de datos reunidos fuera del contexto de cualquier teoría particular con la esperanza de que surjan nuevos fenómenos. Como ejemplo se tiene el Human Brain Project (HBP), una iniciativa multinacional europea de investigación del cerebro para avanzar en neurociencia, ciencias de la salud y para crear tecnología bioinspirada en el cerebro humano [4]. Se estima que son necesarios 60 Petabytes de datos para simular el cerebro de un ratón, y unos 200 exabytes si hablamos de un cerebro humano [5]. En biología se estima que para 2025 se almacenen de 2 a 40 Exabytes de datos genómicos [6]. Otro ejemplo en astronomía sería el telescopio LSST (Large Synoptic Survey Telescope) que produce 15 Terabytes de información cada noche. Estos datos corresponden a imágenes y datos del universo que son utilizados por los científicos, entre otros, para el entendimiento de la materia y

energía oscura, estudio de sistemas planetarios extrasolares, detección de asteroides potencialmente peligrosos o la formación y estructura de la vía láctea [7]. En el mismo campo se tiene el proyecto Gaia que está enfocado a realizar el censo astronómico más exhaustivo realizado jamás de la vía láctea, donde se espera recabar más de 1 Petabyte de información [8]. Los rápidos avances en instrumentación significan que los ingenieros pueden recopilar fácilmente cantidades masivas de datos sobre sistemas complejos y usar esos datos para la gestión y el control.

3. Mucha de la actividad humana tiene lugar en internet y esta actividad genera datos con valor comercial y científico. Como ejemplo más significativo se tiene toda la información que se está generando en las redes sociales. Esta información está ayudando a profundizar, por ejemplo, en los campos del marketing, la sociología y la psicología.
4. Crecimiento significativo en el despliegue de redes de sensores que registran fenómenos biológicos, físicos y sociales a una escala cada vez mayor, estando estas redes de sensores cada vez más interconectadas. Esta tendencia se conoce en la industria como IoT (Internet of Thing).

En general, estas grandes cantidades de datos se están empezando a explotar de manera efectiva, por lo que la ciencia tiene la posibilidad de extender su alcance, y hacer que la tecnología se vuelva más adaptable, personalizada y robusta.

Varias décadas de investigación y desarrollo en bases de datos y motores de búsqueda han desarrollado una experiencia relevante en el diseño de tecnología escalable centrada en datos. En particular, estos campos han impulsado la computación en la nube y otras plataformas paralelas y distribuidas adecuadas para el análisis de estos datos. Por otra parte, las innovaciones en los campos del aprendizaje automático, la minería de datos, la estadística y la teoría de los algoritmos han generado métodos de análisis de datos que se pueden aplicar a conjuntos de datos cada vez más grandes.

Indudablemente hay dificultades importantes que surgen al intentar alcanzar los objetivos que se prevén en las discusiones sobre datos masivos. En parte, estas dificultades son las habituales de las implementaciones de bases de datos de gran escala, que involucran encontrar y mitigar los cuellos de botella, logrando simplicidad y generalidad de la interfaz de programación, propagando metadatos, diseñando un sistema que es robusto a los fallos de hardware, y explotando hardware paralelo y distribuido, todo a una escala sin precedentes. Pero la utilidad de estos datos masivos va más allá del almacenamiento, indexación y consultas que han sido la competencia de sistemas de bases de datos

y motores de búsqueda clásicos, siendo el principal de ellos el relacionado con la inferencia. La inferencia es el problema de convertir los datos en el conocimiento, donde el conocimiento a menudo se expresa en términos de variables (por ejemplo, el estado general de salud del paciente o la tendencia de un comprador a comprar) que no están presentes en los datos per se, pero están presentes en los modelos que uno usa para interpretar los datos.

En la Tabla 1-1 se pueden ver ejemplos de casos de uso clasificados por áreas de conocimiento [2].

**Tabla 1-1:** Campos de la ciencia y la ingeniería impactados por datos masivos

Áreas de conocimiento	Casos de uso más relevantes
Ciencias físicas	Astronomía, física de partículas
Climatología	Predicción meteorológica
Procesamiento de señales	Control inteligente
Medicina	Imágenes, registros médicos
Inteligencia artificial	Procesamiento de lenguaje natural, visión artificial
Marketing	Publicidad en internet, programas de fidelización de clientes
Ciencias políticas	Modelado basado en agentes del cambio de régimen
Investigación forense	Detección de fraudes, tráfico de drogas/personas/CBRNe <sup>1</sup>
Estudios culturales	Usos del suelo, geografía cultural
Sociología	Sociología comparada, redes sociales, demografía, creencias y difusión de la información
Biología	Genómica, proteómica, ecología
Neurociencia	fMRI <sup>2</sup> , registros multi-electrodos
Psicología	Psicología social

### 1.3.2. Infraestructuras: escalando mediante sistemas distribuidos y paralelos

El procesamiento masivo de datos, almacenamiento y análisis requerirán el soporte de sistemas de procesamiento distribuidos y paralelos. Debido a que la

<sup>1</sup> Chemical, Biological, Radiological, Nuclear, enhanced improvised explosive devices)

<sup>2</sup> Functional Magnetic Resonance Imaging

velocidad de procesamiento de la microelectrónica no está aumentando tan rápidamente como solía hacerlo, se está optando por el desarrollo de CPUs (Central Processing Unit) altamente paralelas. Esta es la única forma de continuar con las mejoras de rendimiento a gran escala que demandan las actuales aplicaciones.

Para permitir estas mejoras de rendimiento en el procesamiento, las operaciones de entrada/salida (I/O) y de almacenamiento también deben ser paralelizadas y distribuidas. La Ley de Amdahl, una regla general que ha sido válida durante casi 50 años, afirma que un sistema equilibrado necesita un bit de I/O por ciclo de CPU y, por lo tanto, las mejoras en la velocidad de procesamiento deben ir acompañadas de mejoras en I/O. Un alto rendimiento de I/O requiere un uso intensivo de almacenamiento de datos local, por lo que el almacenamiento necesita ser tan distribuido y paralelo como el procesamiento.

La razón por la que el cálculo de un único subproceso sigue siendo tan común es que los sistemas paralelos y distribuidos son difíciles de configurar y mantener, y el software paralelo y distribuido es difícil de escribir. El fin de la era en la que las nuevas generaciones de CPUs eran cada vez más rápidas, ha llevado al uso de nuevos sistemas paralelos de programación y gestión de datos que son más fáciles de usar.

#### 1.3.2.1. Paralelismo Hardware

El "paralelismo hardware" se define aquí como la presencia en un sistema de muchos elementos de cómputo independientes que operan simultáneamente. En algunos casos los elementos realizan tareas altamente especializadas y, como resultado, pueden hacer muy rápido ciertas tareas con muchos elementos operando en paralelo. Un ejemplo de paralelismo de hardware son los circuitos integrados para el procesamiento de señal que pueden realizar transformadas rápidas de Fourier como una operación de hardware. Los desarrollos más recientes están motivados por problemas en la administración de redes y por el hardware desarrollado para acelerar gráficos por computadora.

Los equipos de red especializados, como la supervisión de redes de muy alta velocidad y el equipo de cortafuegos, suelen utilizar hardware especializado conocidos como FPGA (Field Programmable Gate Array) y TCAM (Ternary Content Addressable Memory). Las FPGAs son circuitos integrados personalizables que se puede configurar para un alto rendimiento en tareas de propósito especial. Un TCAM es similar a una memoria caché, pero los chips TCAM permiten al usuario especificar reglas de desempate en el caso de

múltiples coincidencias. Por ejemplo, los TCAM almacenan rangos de direcciones de subred de interés y las FPGAs realizan tareas especializadas, como la coincidencia de expresiones regulares en el contenido del paquete y el enrutamiento (tal vez a un host para monitoreo) basados en los resultados del TCAM y otros análisis. Las FPGAs también han encontrado uso en los motores analíticos de los datawarehouse, realizando filtrado y otras tareas en la transmisión de datos desde el disco [2]. En la Figura 1-1 se puede ver un ejemplo de esta clase de arquitectura de la plataforma PureData System for Analytics de IBM [9].

Otro desarrollo reciente e importante en paralelismo hardware han sido las unidades de procesamiento gráfico (GPUs – Graphics Processing Unit) desarrolladas para acelerar las tarjetas gráficas. Este tipo de procesadores son altamente paralelos, desarrolladas inicialmente para acelerar aplicaciones gráficas y juegos de computadora [2]. Varios proveedores (NVIDIA, ATI, IBM) han desarrollado tales plataformas, que se utilizan cada vez más para aplicaciones que requieren un rendimiento de coma flotante muy alto. En la Figura 1-2 se muestra la arquitectura de la tarjeta Nvidia GeForce 8800 GTX. Muchos de los 500 ordenadores más importantes del mundo, en cuanto a velocidad de cálculo, son máquinas híbridas que consisten en una gran variedad de CPUs y GPUs tradicionales, en combinación con una CPU para acelerar aplicaciones de aprendizaje profundo (Deep Learning), análisis e ingeniería. NVIDIA introdujo esta tecnología en 2007 y, desde entonces, las GPUs han pasado a instalarse en centros de datos energéticamente eficientes de laboratorios gubernamentales, universidades, grandes compañías y PYMEs de todo el mundo. Este tipo de procesadores desempeñan un papel fundamental en la aceleración de aplicaciones que abarcan desde la inteligencia artificial hasta los automóviles, drones y robots [10]. Como dato curioso comentar que, ciertas GPUs son difíciles de conseguir debido al “boom” de la generación de criptomonedas. En los últimos meses sus precios se han llegado a triplicar debido a este hecho.

Una tarjeta GPU típica puede superar a una CPU hasta en un orden de magnitud, dependiendo de la aplicación, y el rendimiento de una tarjeta gráfica típica de gama alta supera el teraflop. La operación de ordenación supera la tasa de mil millones de registros por segundo en algunos puntos de referencia. El rendimiento por unidad de potencia disipada también es significativamente mejor con las GPUs que con los procesadores tradicionales, un problema que se está volviendo cada vez más importante para el costo total de propiedad de sistemas informáticos de alta gama.

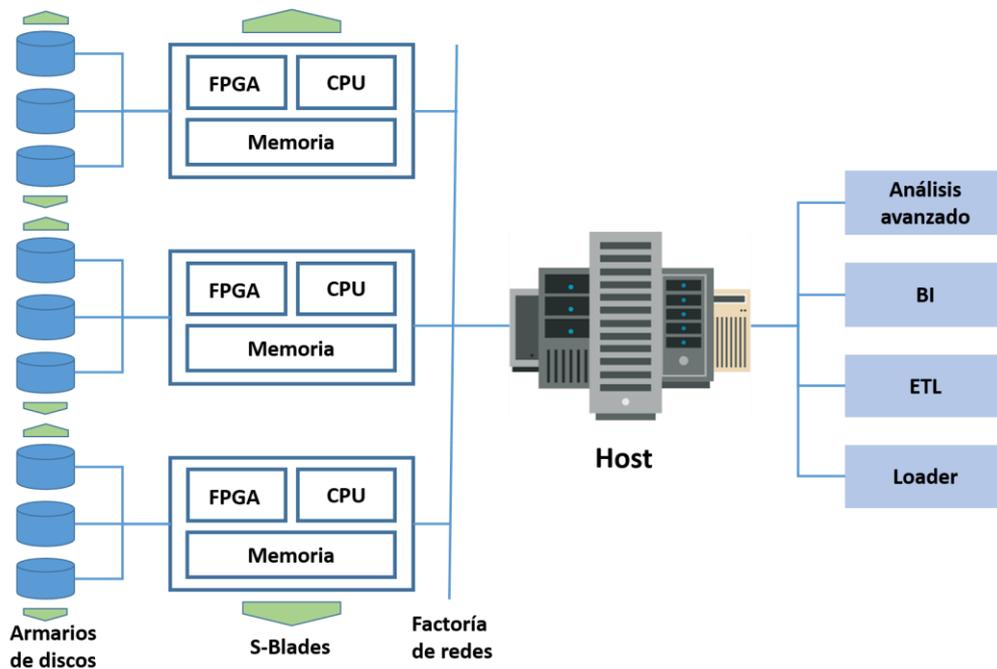


Figura 1-1: Arquitectura de la plataforma PureData System for Analytics de IBM

El cálculo acelerado con GPU traslada las partes de la aplicación con mayor carga computacional a la GPU y deja el resto del código ejecutándose en la CPU.



Figura 1-2: Ejemplo de arquitectura de la GPU de la tarjeta gráfica de Nvidia GeForce 8800 GTX

La principal desventaja en la aplicación de GPU a gran escala de datos masivos es que la memoria adjunta a las tarjetas es bastante limitada (típicamente 2-6 gigabytes (GB), hasta 32 GB actualmente). Mientras que el acceso a los datos de la memoria de la tarjeta es muy rápido, más de 100 GB/s, mover datos dentro y fuera de las tarjetas puede ser un importante cuello de botella.

Además, la programación de GPU es aún bastante complicada, requiriendo entornos bastantes específicos (por ejemplo, CUDA<sup>3</sup>, OpenCL<sup>4</sup>). No obstante, la situación mejora cada año, a medida que aumentan los algoritmos portados al entorno de la GPU. Como ejemplo se tienen las librerías de Keras [11], Theano [12] o Tensorflow [13].

### 1.3.2.2. CPUs multinucleo

Durante la última década, las CPU convencionales de los servidores han ganado internamente paralelismo de dos maneras:

1. Aumentando el número de núcleos por chip o por paquete.
2. Aumentando el número de operaciones que un núcleo puede ejecutar por ciclo, en gran medida por medio de operaciones paralelas en vectores cortos de datos.

Ambas tendencias aumentan el desafío de hacer un buen uso de los recursos computacionales disponibles en aplicaciones reales. Las actuales herramientas para paralelizar y vectorizar automáticamente aplicaciones no son muy efectivas. Hasta la fecha, el crecimiento en el número de núcleos por chip ha sido algo restringido, en particular la necesidad de mantener un buen rendimiento en código no paralelo. Pero la industria es consciente de que un pico más alto de rendimiento, y un mayor rendimiento por vatio, se puede lograr integrando un número mucho mayor de núcleos funcionando a velocidades más bajas [14].

### 1.3.2.3. Memorias Flash

La rápida proliferación de las memorias flash es otra tendencia relevante. Tradicionalmente, los diseñadores de sistemas se han visto forzados a elegir entre rendimiento y seguridad al construir sistemas de almacenamiento a gran escala. El almacenamiento flash tiene el potencial de alterar drásticamente esta compensación, proporcionando persistencia y alto rendimiento y baja latencia. La

---

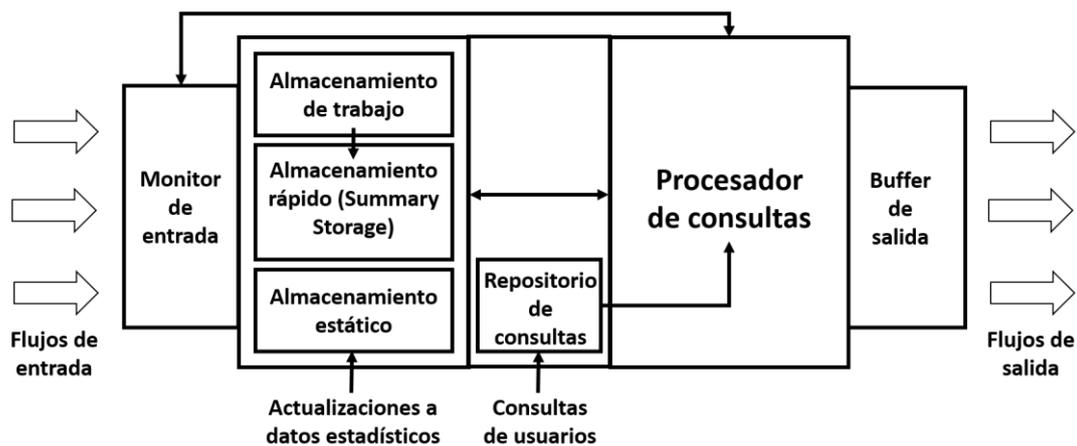
<sup>3</sup> Compute Unified Device Architecture

<sup>4</sup> Open Computing Language

llegada de unidades flash básicas crea nuevas oportunidades en el centro de datos, lo que permite nuevos diseños que no son prácticos con infraestructuras de disco magnético o RAM (Random Access Memory) [15].

#### 1.3.2.4. Sistemas de gestión de flujos de datos

Los sistemas de gestión de flujo de datos, también conocidos por sus siglas en inglés DSMS (Data Stream Management System) han surgido como un tema de investigación importante en la última década, donde se han desarrollado muchos sistemas de investigación (Stream, Niagara, Telegraph, Aurora, Cougar) y sistemas comerciales (Streambase, Coral8, Aleri, InfoSphere Streams, Truviso). Un DSMS ejecuta una colección de consultas permanentes en una o más secuencias de entrada. Los flujos de datos son generalmente informes en tiempo real de fenómenos en vivo. Se puede ver la arquitectura general de este tipo de sistemas en la Figura 1-3.



**Figura 1-3:** Arquitectura abstracta de referencia para un sistema de gestión de flujos de datos (DSMS) [16]

Existen 2 métodos principales para escribir consultas a un DSMS [2]:

1. Utilizando un lenguaje de consulta altamente estructurado, a menudo una variante de SQL (Structure Query Language), como lenguaje de consulta contextual, CQL (Contextual Query Language), que ha sido desarrollado para consultas sobre flujos de datos. Estos lenguajes de flujo difieren del SQL convencional en que generalmente requieren consultas para usar construcciones de ventanas para limitar el alcance de los datos utilizados para calcular cualquier registro de salida.
2. La segunda opción usa metodología gráfica de "cajas y flechas". Los cuadros representan tareas de procesamiento de datos (o fuentes de datos)

y las flechas representan el flujo de datos. El programador selecciona y personaliza los cuadros, luego los conecta con flechas para desarrollar una especificación de procesamiento de datos, a menudo a través de una interfaz gráfica de usuario (por ejemplo, Streambase, Infosphere Streams). La motivación para el método de programación “cajas y flechas” es que muchos análisis de flujo son difíciles para expresar en un lenguaje similar a SQL.

### 1.3.2.5. Computación en la nube

La computación en la nube, el sueño desde hace mucho tiempo de la computación como servicio público, está transformando una gran parte del negocio de las tecnologías, por ejemplo, haciendo que el software sea más atractivo contratarlo como servicio, lo que se conoce como SaaS (Software as a Service). Este hecho está cambiando la forma en la que se están realizando las inversiones en hardware, así como su diseño. Las necesidades de hardware para análisis de datos masivos se están beneficiando del escalado que permite esta tecnología, sin necesidad de grandes inversiones en grandes centros de procesamiento de datos y obviando además el gasto en horas hombre que sería necesario para operar un centro de datos tradicional. Ya no es necesario preocuparse por el exceso o defecto de hardware adquirido para un servicio cuya demanda no cumple con sus predicciones, por lo tanto, malgastar recursos costosos, o desabastecimiento en caso de que se necesiten mayores recursos. Por otra parte, las empresas o instituciones con grandes tareas orientadas a lotes (procesos batch) pueden escalar rápidamente sus programas, ya que usar 1.000 servidores durante una hora no cuesta más que usar un servidor durante 1.000 horas [17]. En la Figura 1-4 se puede ver la arquitectura típica de un servicio SaaS.

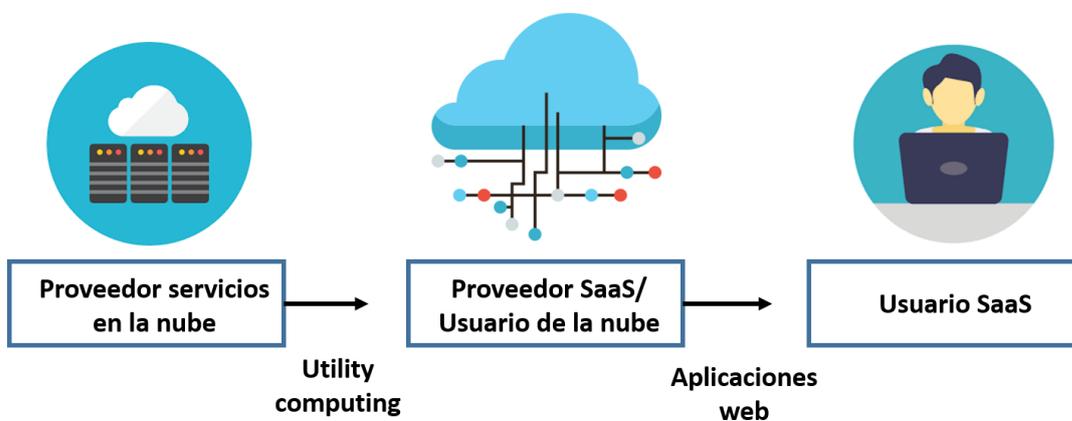


Figura 1-4: Arquitectura básica de servicios en la nube y software como servicio (SaaS) [17]

Sobre los obstáculos y oportunidades que presentan los servicios en la nube se

puede ver una lista de los mismos en la Tabla 1-2, donde se muestra mayor detalle de ellos en [17].

Uno de los proveedores de servicios en la nube más exitosos es el de Amazon, conocido como AWS (Amazon Web Services), que comenzó a dar este tipo de servicios en 2006. Ejemplos de servicios populares son EC2 (Elastic Compute Cloud) que permite configurar máquinas virtuales de forma sencilla, escalable y de pago por uso [18]. Para el caso de clusters de GPUs se tienen las instancias P2 [19]. Las instancias S3 (Simple Storage Service) permiten almacenamiento persistente a unos precios muy ventajosos [20]. Como competencia más destacada se tienen los servicios en la nube de Microsoft conocida como Azure [21].

**Tabla 1-2:** Los 10 mayores obstáculos y oportunidades de crecimiento de los servicios en la nube según [17]

Obstáculo	Oportunidad
1. Disponibilidad	Utilización de múltiples proveedores de servicios en la nube
2. Datos atrapados	Estandarización de APIs (Application Programming Interface)
3. Confidencialidad de datos y auditabilidad	Despliegue de capacidades de cifrado, VLAN <sup>5</sup> , cortafuegos
4. Cuellos de botella en la transferencia de datos	Mayor velocidad en discos y mayor número de Switches de banda ancha
5. Imprevisibilidad del rendimiento	Mejoras del soporte a VM <sup>6</sup> ; memorias flash; grupo de planificación de VMs
6. Almacenamiento escalable	Idear almacenamiento escalable
7. Errores en grandes sistemas distribuidos	Crear depuradores que se apoyen en VMs distribuidos
8. Velocidad de escalado	Idear autoescalado basado en aprendizaje automático; Desarrollo de Snapshots
9. Reputación compartida	Ofrecer servicios de protección de la reputación
10. Licenciamiento de software	Pago de licencias por uso

<sup>5</sup> Virtual Local Area Network

<sup>6</sup> Virtual Machine

### 1.3.2.6. MapReduce

MapReduce es un modelo de programación y una implementación asociada para procesar y generar grandes conjuntos de datos. Los usuarios especifican una función *map* que procesa un par clave/valor para generar un conjunto de pares clave/valor intermedio, y una función *reduce* que combina todos los valores asociados intermedios con la misma clave intermedia. Muchas de las tareas del mundo real pueden ser implementadas bajo este modelo.

Los programas escritos en este estilo funcional son automáticamente paralelizados y ejecutados en un gran clúster de máquinas básicas. El sistema de tiempo de ejecución se encarga de los detalles de la partición de los datos de entrada, la planificación de la ejecución del programa a través de un conjunto de máquinas, la gestión de los fallos de la máquina y la administración de la comunicación de la inter-máquina requerida. Esto permite a los programadores sin ninguna experiencia en sistemas paralelos y distribuidos utilizar los recursos de un gran sistema distribuido de forma sencilla [22]. En la Figura 1-5 puede verse un esquema de ejecución MapReduce.

Este tipo de programación ha sido popularizado por Google para sus operaciones internas. La versión de código abierto de MapReduce ha recibido el nombre de Hadoop y ha gozado de gran popularidad.

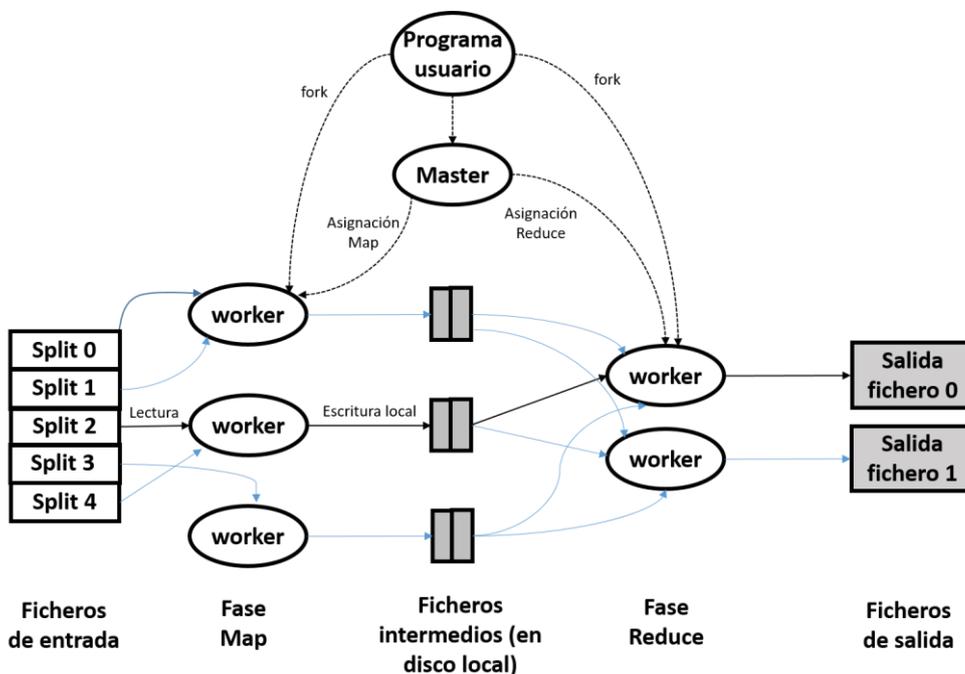


Figura 1-5: Visión de conjunto de ejecución de MapReduce [22]

### 1.3.2.7. Sistemas y lenguajes de programación paralela

El desarrollo de programas paralelos y/o distribuidos es notoriamente difícil debido a los problemas para encontrar recursos, distribuir el trabajo, recopilar resultados, recuperarse de fallas y comprender y evitar condiciones no deseables. Se han desarrollado una variedad de herramientas para reducir la carga de desarrollar programas paralelos y distribuidos, por ejemplo, las basadas en paso de mensajes como la interfaz de paso de mensaje (MPI – Message Passing Interface), la máquina virtual paralela (PVM – Parallel Virtual Machine) o la invocación de método remoto (RMI – Remote Method Invocation) en Java. Sin embargo, la programación paralela con estas herramientas de nivel intermedio sigue siendo difícil porque el programador se ve obligado a especificar muchos detalles sobre cómo gestionar el paralelismo. El acceso simple a la programación paralela parece requerir lenguajes que sean al menos parcialmente funcionales (por ejemplo, MapReduce) o declarativos (por ejemplo, SQL). Un método para lograr el paralelismo de forma sencilla es crear lenguajes cuyas primitivas realizan costosas operaciones en estructuras de datos muy grandes. Las grandes operaciones matriciales, como la multiplicación o la inversión, son costosas, pero fácilmente paralelizables. Lenguajes como MATLAB, S, Splus y R, para los cuales la estructura de datos básica es una matriz, pueden ser, por lo tanto, alentadoras ayudas al paralelismo [23].

### 1.3.3. El cuarto paradigma: eScience

Varios paradigmas de generación de conocimiento científico a lo largo de la historia han sido descritos [24]:

1. **Empirismo:** En este primer estadio y durante miles de años, el conocimiento científico fue generado a partir de observaciones de fenómenos naturales. Por ejemplo, esta época es la de Ptolomeo, cuyo trabajo consistió en estudiar los datos existentes sobre el movimiento de los planetas con el fin de construir un modelo geométrico que explicase dichas posiciones en el pasado y fuese capaz de predecir sus posiciones futuras.
2. **Rama teórica:** desde hace unos pocos cientos de años se han desarrollado modelos y generalizaciones que describen los diferentes fenómenos de la naturaleza. Un ejemplo de este paradigma serían las Leyes de Newton o la Teoría de la Relatividad de Einstein.
3. **Rama computacional:** esta rama del conocimiento fue desarrollada varias décadas atrás coincidiendo con el desarrollo de las computadoras. Este paradigma utiliza estas computadoras para realizar simulaciones de

fenómenos complejos de la naturaleza y estudiar su comportamiento.

4. **eScience:** Este cuarto paradigma fue nombrado por primera vez en 2007 por Jim Gray [25]. Se describe eScience como un método de investigación que implica la recopilación, el procesamiento y la utilización de información científica en forma de datos [26]. Los métodos cada vez más eficientes de recopilación, generación, digitalización y posterior almacenamiento de datos abren nuevas oportunidades para realizar investigaciones en todas las áreas profesionales y académicas. El procesamiento de grandes volúmenes de datos disponibles, incluidos cálculos, modelos y visualizaciones de computadoras, permite la solución y la comprensión de problemas complejos de problemas que antes no eran accesibles. Tradicionalmente, eScience se ha utilizado principalmente en las disciplinas de las ciencias naturales, como la física de partículas y la bioinformática. Sin embargo, la aplicación de eScience en otros contextos va en aumento, y el potencial para obtener nuevos resultados de investigación es enorme.

#### 1.3.4. eScience aplicada al estudio de la fusión nuclear

Un ejemplo de lo anteriormente descrito son los plasmas generados en dispositivos de confinamiento magnético. Como ejemplo mencionar JET (Joint European Torus) que puede generar 10 gigabytes de información para pulsos de 40 segundos. Un amplio conjunto de señales como son formas de onda, imágenes y líneas de nivel, son adquiridas en tiempo real a través de los diagnósticos que se describirán en el capítulo siguiente. Esta necesidad de almacenamiento y análisis se ve incrementada ante la duración prevista de las descargas en futuras máquinas tales como ITER (International Thermonuclear Experimental Reactor) o Wendelstein 7-X. Por lo que tales descargas producirán un volumen de datos significativamente mayor al actual. Para el caso de ITER se espera poder realizar pulsos que duren entre 300 y 3.000 segundos, con lo que se producirán cientos de Petabytes de información cada año [27].

### 1.4. Objetivos

En la operación de plasmas de pulso largo, como por ejemplo ITER, el reconocimiento automático de eventos puede ser una tarea de gran importancia. El término *evento* se utiliza para identificar cualquier clase de cambio en el flujo de datos, donde la palabra cambio se refiere a una diferencia cualitativa en la secuencia de evolución temporal. El reconocimiento automático de cambios es útil en el análisis de datos en tiempo real, por ejemplo, activando y desactivando

la adquisición de señales o incrementando/decrementando la frecuencia de muestreo en tiempo real, centrando la atención en los intervalos de tiempo relevantes.

En este sentido, el objetivo principal del trabajo desarrollado en esta tesis doctoral consiste en la aplicación a entornos de fusión nuclear de una técnica de propósito general para la detección de cambios en flujos de datos variables en el tiempo, sin la necesidad de generar desarrollos particulares para cada problema específico. Dicha técnica está basada en una metodología de aprendizaje automático [28]. Con este método, en cada instante de tiempo las muestras de datos tienen una representación multidimensional. Por ejemplo, cada muestra puede ser un vector cuyos componentes son la amplitud de diferentes formas de onda o el píxel de intensidad de una imagen. Con este propósito se han estudiado 3 posibles aplicaciones a entornos de fusión:

1. **Detección de cambios en perfiles del TJ-II (Tokamak de la Junta II):** dichos perfiles pueden corresponder, por ejemplo, a la temperatura, densidad o radiación del plasma. Los cambios simulados pueden deberse a la inyección de calentamiento adicional en el plasma, al aumento de impurezas o a la presencia de una mayor actividad de MHD (Magnetohidrodinámica) en el plasma.
2. **Identificación de cambios en imágenes de video:** en bruto o procesadas, desde un sistema de adquisición de datos que en este caso será una cámara de video de alta velocidad. Estas imágenes tienen un contenido de información que permite profundizar en el conocimiento físico del plasma. Un cambio en estas imágenes de evolución temporal es la identificación de alteraciones en el estado del plasma de fusión. Con este propósito fue desarrollado UMEL (Universal Multi-Event Locator) [29]. En este trabajo se demuestra que el test de martingala es mucho más eficiente, computacionalmente hablando, que UMEL.
3. **Identificación de disrupciones:** se analiza SPAD (Single signal Predictor based on Anomaly Detection) que fue descrito en [30] y previamente nombrado como PBOD (Predictor Based on Outlier Detection) en [31], [32] y [33] como detector de disrupciones. Una de las posibles debilidades de SPAD es la que tiene que ver con el valor del parámetro  $K$ , ya que dicho valor se basa en un criterio empírico. Este hecho hace que, dependiendo del dispositivo nuclear, el valor de  $K$  sea distinto. Un posible sustituto del criterio de anomalía descrito en la sección 4.4.1.2 podría ser el test de martingala.

## 1.5. Estructura de la tesis

El presente trabajo se ha estructurado en 5 capítulos. El capítulo 1 comienza con las necesidades y soluciones energéticas en el mundo actual para seguidamente, presentar el Big Data como ciencia y tecnología a la hora de tenerle presente en las implementaciones futuras. En el capítulo 2 se hace una introducción al concepto de fusión nuclear y un resumen de la física que rige los plasmas de fusión, tipo de dispositivos de fusión, así como una introducción al problema de las interrupciones que aparece en los dispositivos de tipo tokamak.

En el capítulo 3 se introduce la teoría que subyace en la arquitectura de martingalas que se ha utilizado en esta tesis. Se muestra primeramente el concepto teórico de cambio y el estado del arte en la detección de cambios, así como los requisitos que debería cumplir un algoritmo de este tipo. Adicionalmente se describirá la teoría de predictores conformales y el concepto de intercambiabilidad *On-Line*. Seguidamente se verá el concepto de martingala y diferentes implementaciones de las mismas. Finalmente, el capítulo termina describiendo una arquitectura que ensamble todos los elementos anteriores para la construcción de un algoritmo de propósito general para la detección de cambios.

A continuación, en el capítulo 4 se describirán las diferentes aplicaciones con las que se ha experimentado en el entorno de la fusión nuclear. Es decir, la detección de cambios en perfiles de fusión, la localización de cambios en imágenes de video procedentes de diagnósticos de JET y la detección de interrupciones.

Finalmente, en el capítulo 5 se resumen y valoran los objetivos alcanzados y se proponen nuevas vías de trabajo futuro.

## 2. FUSIÓN NUCLEAR

---

*"I would like nuclear fusion to become a practical power source. It would provide an inexhaustible supply of energy, without pollution or global warming."*

*Stephen Hawking*

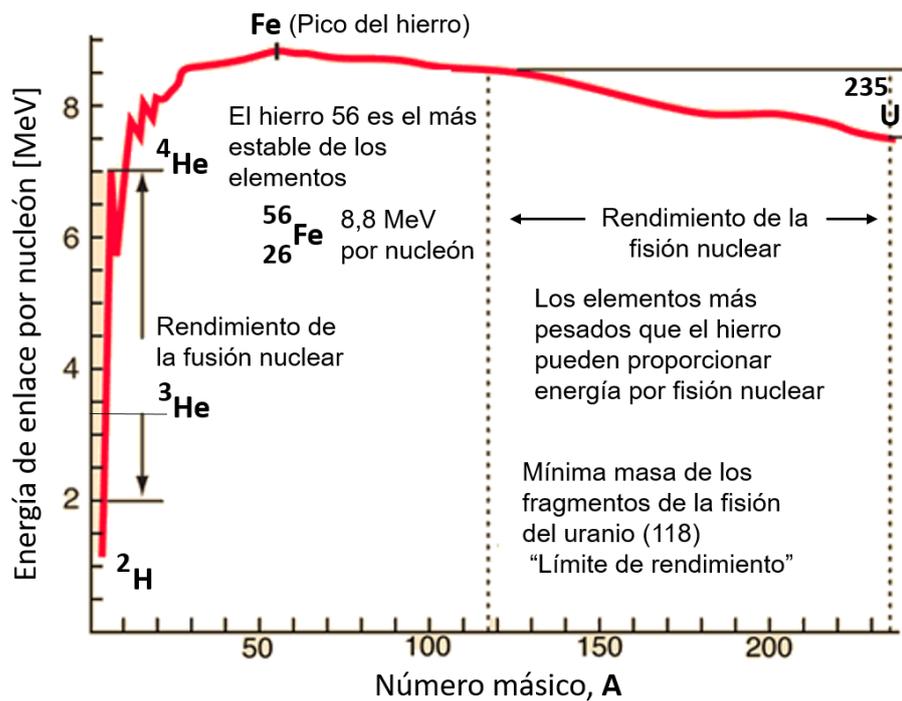
### 2.1. Reacciones nucleares

Los núcleos atómicos consisten en protones y neutrones que se empaquetan en una forma extremadamente compacta en una pequeña región del espacio. Ambos tienen una masa casi idéntica, que es 1.836 veces más grande que la masa del electrón. El tamaño (radio) de un núcleo viene dado aproximadamente por la expresión:

$$R = r\sqrt[3]{a} \qquad \text{Ec. 2-1}$$

Donde  $r=1,5 \times 10^{-13}$  cm y  $a$  es el número de nucleones en el núcleo.

$Z$  ó número atómico, representa el número de protones en el núcleo.  $A$  es el número de protones ( $Z$ ) y neutrones ( $N$ ) del núcleo de un átomo,  $A = Z + N$ . La variación de  $A-Z$  para cualquier  $Z$  dado, da lugar al fenómeno de los isótopos. Dos isótopos del hidrógeno: el deuterio y el tritio, son muy relevantes para la fusión, como se verá más adelante. A menudo, los isótopos de un elemento natural son radiactivos y se transforman de manera espontánea en otros elementos. Por ejemplo, el tritio tiene una emisión beta débil (con un promedio de energía de 5,7 keV y un máximo de energía de 18,6 keV) y con una vida media de 12,35 años. Sin embargo, este fenómeno no es de gran importancia para la fusión ya que los tiempos característicos en los que el proceso de fusión se produce son lo suficientemente cortos como para que este decaimiento ocurra muy a menudo.



**Figura 2-1:** Gráfico de las energías de enlace nuclear según la masa atómica. El rendimiento para la fusión es mucho mayor que para la fisión

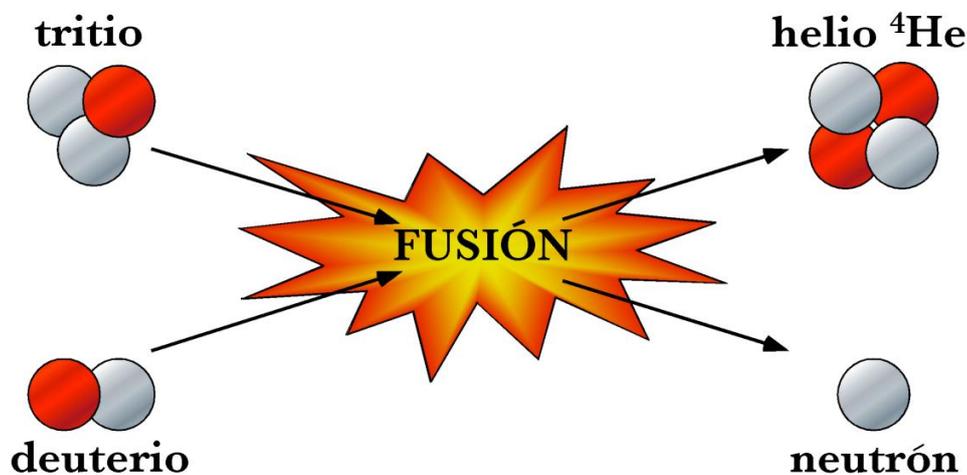
Dentro de los núcleos las fuerzas de repulsión entre los protones cargados positivamente son mucho menores que las fuerzas nucleares atractivas que mantienen unido el núcleo. Es necesario invertir una cantidad de energía con el fin de extraer un nucleón del núcleo, y cuando un nucleón es capturado por un núcleo, esta misma energía se libera. En la Figura 2-1 se puede ver que la energía requerida depende del número másico A, pero tiene un valor máximo de alrededor de 8 MeV para los núcleos próximos al hierro. En la fisión, elementos con fuertes energías de enlace menores de 8 MeV se rompen en núcleos más ligeros, por lo tanto, la liberación de energía desde los núcleos resultantes está más cerca del hierro. Por otro lado, en la fusión, dos núcleos ligeros se combinan produciendo uno más pesado, que también está más cerca del hierro. Este último proceso es el que hace que las estrellas tengan un núcleo de hierro hacia el final de sus vidas. Tanto en la fisión como en la fusión, se libera una considerable cantidad de energía, equivalente a la disminución de la masa total de los núcleos del producto con respecto a la masa inicial. La diferencia de masa se libera como energía, de acuerdo con la famosa ecuación de Einstein:

$$e = mc^2$$

Ec. 2-2

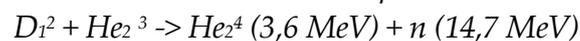
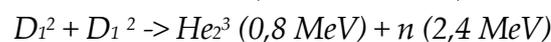
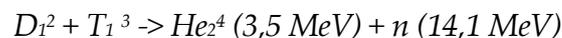
Para formar un núcleo de más de un elemento, es necesario que estén lo

suficientemente juntos para que las fuerzas atractivas nucleares funcionen. Con este fin, tendrán que superar la fuerza repulsiva de Coulomb, que actúa como una barrera, antes de que las fuerzas nucleares atractivas pueden entrar en juego. La fuerza de repulsión de Coulomb es proporcional a la carga del núcleo y, por tanto, los plasmas formados por los núcleos de la familia de hidrógeno son los más adecuados para conseguir la fusión. Existen diversas reacciones de fusión que pueden ser útiles desde el punto de vista energético. De todas las reacciones que implican isótopos de hidrógeno, la reacción deuterio-tritio tiene la mayor sección eficaz para temperaturas relativamente bajas y, por tanto, es más fácil de conseguir de una manera controlada. La reacción produce un neutrón de alta energía y helio uno, tal y como se muestra en la Figura 2-2.



**Figura 2-2:** Representación esquemática de la reacción de fusión D-T. Un núcleo de helio y un neutrón, liberándose una energía de 17,58 MeV

Las reacciones de fusión más sencillas de realizar en la tierra son las que se consiguen a partir de isótopos del hidrógeno:



Donde D es un deuterón, T un tritón, H un protón, n un neutrón y He<sup>4</sup> es un isótopo de helio. Las secciones eficaces para estas reacciones se indican en la Figura 2-3, donde se observa que por debajo de 1 keV éstas tienen unos valores muy bajos, aunque crecen muy deprisa. En torno a temperaturas del orden de 10 keV (alrededor de 100 millones de grados centígrados), la reacción entre el D y T es varios órdenes de magnitud más probable que las restantes. Por ello se ha elegido esta reacción para ser utilizada en la primera generación de reactores de

fusión.

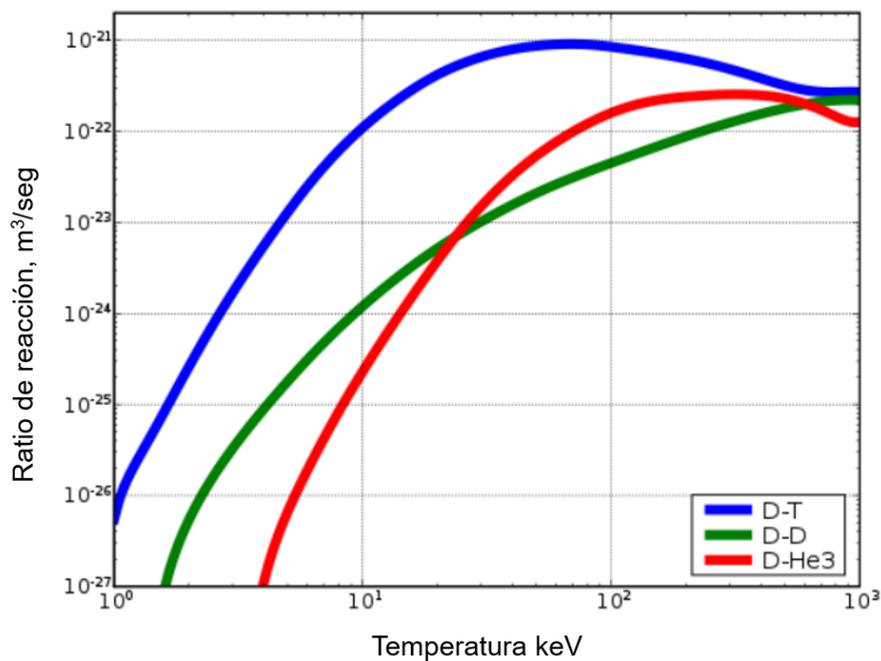
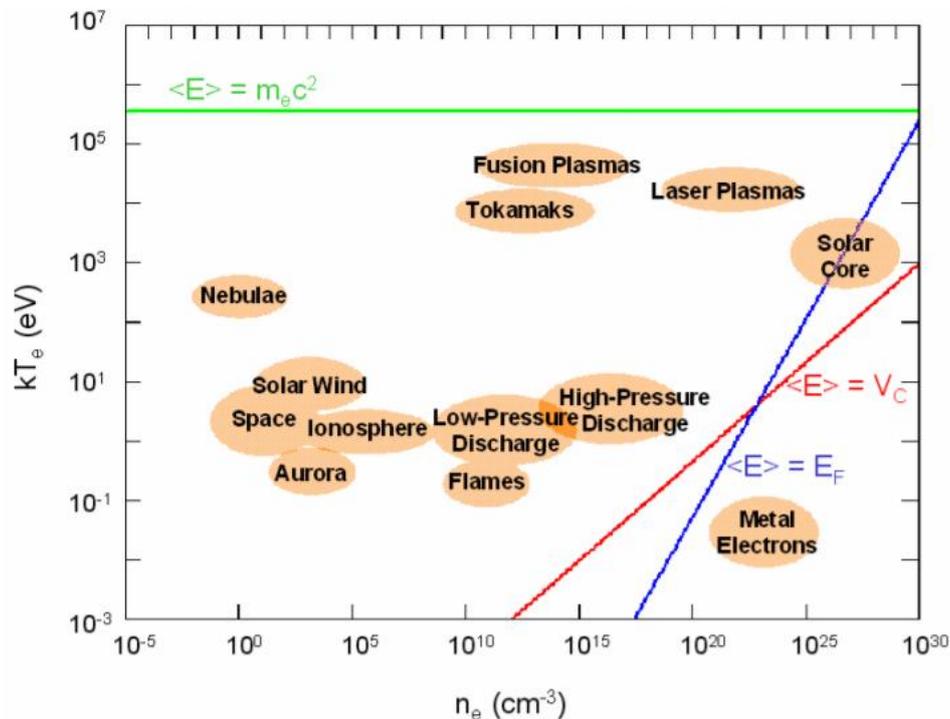


Figura 2-3: Secciones eficaces de las reacciones nucleares D-T, D-D, D-He<sup>3</sup>

## 2.2. Plasmas de fusión

Con el fin de superar la repulsión electrostática entre los núcleos que se quiere fusionar en condiciones de laboratorio, es necesario invertir mucha energía, esto se puede lograr mediante su calentamiento a temperaturas muy altas. En tales condiciones, la materia se encuentra en un estado gaseoso altamente ionizado y exhibe un comportamiento colectivo que se denomina plasma. El 99% del Universo está formado por esos plasmas, o materia ionizada, pero en la naturaleza existe una gran variedad de plasmas, que pueden no poseer las condiciones de altas temperaturas necesarias para conseguir la fusión termonuclear.

Un gas ordinario, como el helio, es un conjunto de átomos eléctricamente neutros, en los que cada átomo contiene un número de electrones con carga negativa que orbitan un pequeño núcleo central compuesto por un número igual de protones cargados positivamente y varios neutrones sin carga eléctrica. Los electrones que orbitan están encerrados junto con el núcleo por las fuerzas atómicas, formando un solo átomo eléctricamente neutro. Debido a sus átomos neutros, un gas ordinario muestra poca respuesta a las fuerzas eléctricas y magnéticas, y es un pobre conductor de electricidad.



**Figura 2-4:** Diferentes tipos de plasmas en astrofísica, física solar y física de estado sólido, fusión nuclear, y para aplicaciones técnicas en un diagrama de temperatura de electrones frente a densidad de electrones. La línea verde denota la limitación de los plasmas no relativistas, los plasmas degenerados y no ideales se colocan directamente desde la línea azul y roja, respectivamente

El gas se convierte en plasma cuando se calienta lo suficiente como para provocar que los electrones queden libres del átomo. Las características de un plasma son muy diferentes de las de un gas ordinario. A diferencia de los gases ordinarios, los plasmas son buenos conductores hasta el punto que no solo son afectados significativamente por las fuerzas electromagnéticas, sino que también pueden llegar a generarlas. Esta autogeneración de fuerzas, como resultado de los movimientos colectivos de partículas cargadas y las corrientes eléctricas en el plasma, producen un comportamiento muy complejo que aún no se ha llegado a comprender en su totalidad. En este sentido, comprender y describir los complejos sistemas dinámicos de los plasmas es un reto científico fundamental. En la Figura 2-4 puede verse diferentes tipos de plasmas en un diagrama de temperatura de electrones frente a densidad de electrones.

### 2.3. Condiciones necesarias para las reacciones de fusión

Como ya se ha expuesto, el fenómeno de la fusión requiere de altas temperaturas.

Adicionalmente también se deben cumplir otras condiciones si se piensa en la fusión como fuente de energía. Como gas caliente, el plasma nunca está totalmente aislado, por lo tanto, está sujeto a diversas pérdidas a través de la radiación, pero también a través de la convección y la conducción. En general, se define un tiempo que sintetiza todas las pérdidas mencionadas, denominado tiempo de confinamiento de energía ( $\tau_E$ ). Con ello nos referimos al momento en que el plasma requiere perder su contenido de energía, si las fuentes de energía que lo alimentan se cortan repentinamente. De alguna manera,  $\tau_E$  caracteriza la calidad del aislamiento del plasma.

Para que la reacción de fusión sea energéticamente viable, la energía generada por las reacciones de fusión debe al menos compensar estas pérdidas. Esta condición impone un límite menor que el producto del tiempo de confinamiento de energía y la densidad de partículas ( $n$ ) dados por el criterio de Lawson:

$$n \tau_E > g(T)f(Q) \quad \text{Ec. 2-3}$$

Donde  $g(T)$  explica la variación de la velocidad de reacción con temperatura  $T$  y  $Q$  corresponde a la relación entre la potencia de fusión generada y la potencia externa suministrada al plasma. El factor  $Q$  se denomina con frecuencia factor de ganancia de potencia de fusión. Hay dos valores característicos de  $Q$ :

1.  $Q = 1$  indica que la potencia producida por el plasma es igual a la potencia acoplada desde el exterior. Esto se conoce como el punto de equilibrio y se aborda en el más eficiente de los dispositivos experimentales actuales.
2.  $Q = \infty$  indica que la aportación de potencia exterior es cero. El plasma es *autosostenible* y se dice que está en ignición.

Para un plasma de deuterio y tritio, la función  $f(Q)$  es equivalente a aproximadamente 1 para  $Q = 1$  y tiende rápidamente hacia 5 para valores más altos de  $Q$ . En estas condiciones, y para una temperatura de 10 keV, se puede escribir el criterio de Lawson:

$$n \tau_E \approx 10^{20} (m^{-3}s) \quad \text{Ec. 2-4}$$

## 2.4. Confinamiento del plasma

Uno de los retos más importantes en el desarrollo de los futuros reactores de

fusión nuclear es el de cómo confinar el plasma, que se encuentra a más de 100 millones de grados centígrados, en un recipiente sin que este se destruya. Con este fin, actualmente se investiga principalmente en dos vías:

1. **Confinamiento inercial.** El confinamiento inercial produce reacciones nucleares de fusión tras el calentamiento y compresión de bolas de hidrógeno (alcanzándose densidades de  $\approx 10^{32}m^{-3}$  y temperaturas de decenas de KeV) durante periodos de tiempo muy cortos (nanosegundos). Para comprimir las bolas a altas densidades y calentarlas se emplean láseres de alta potencia, por lo que para el progreso del confinamiento inercial se requiere un fuerte desarrollo de dichos láseres [34]. El National Ignition Facility (NIF) es el que probablemente ha conseguido el mejor enfoque para lograr la fusión de confinamiento inercial hoy en día (ver Figura 2-5). Después de más de una década de trabajos, comenzaron los experimentos a plena potencia a principios de 2010 [35]. Sin embargo, estos dispositivos requieren una energía láser alta cuyo desarrollo y aplicación en un ciclo continuo están lejos de ser resueltos [36].

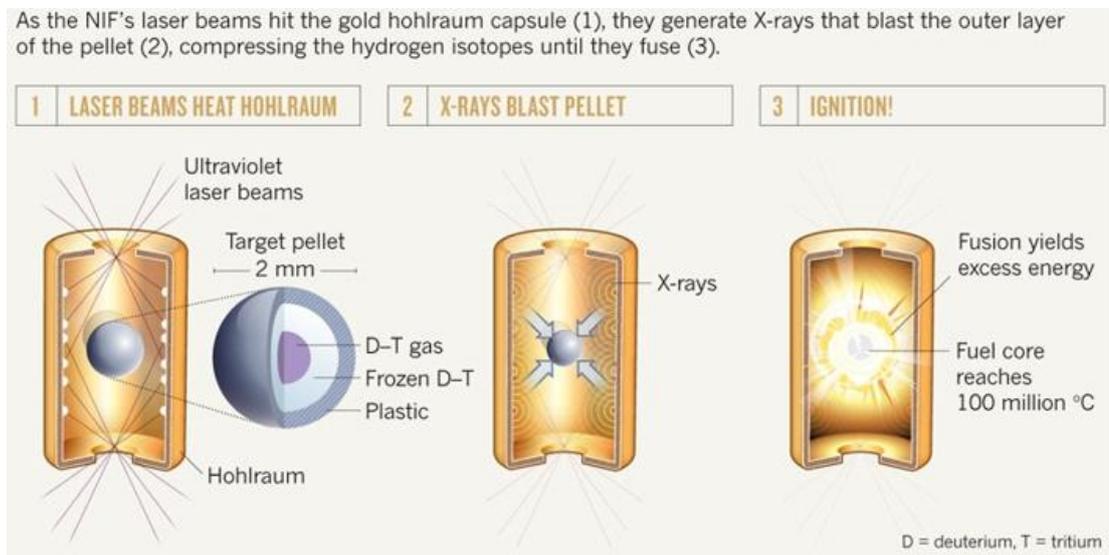
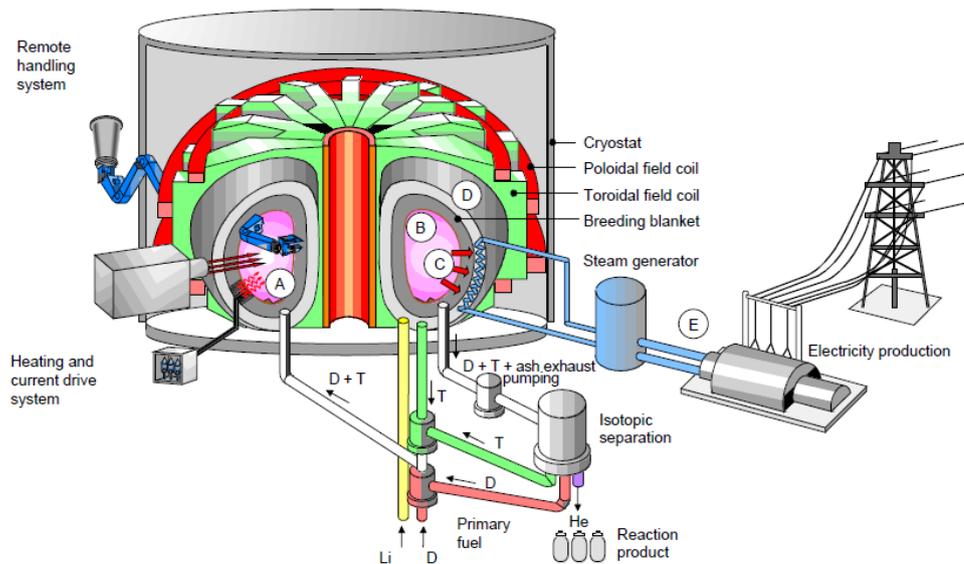


Figura 2-5: Estrategia de NIF (National Ignition Facility) para fusión

2. **Confinamiento magnético.** En los dispositivos de confinamiento magnético se emplean campos magnéticos para mantener aislado el plasma de la cámara de vacío. El plasma, normalmente formado a partir de átomos de hidrógeno y sus isótopos (con densidades de  $10^{20}m^{-3}$ ), se calienta a temperatura muy elevada (decenas de keV) y con un tiempo de confinamiento de la energía alto (del orden de segundos). El confinamiento

magnético se consigue porque el plasma, aunque macroscópicamente neutro, está compuesto por partículas cargadas (iones y electrones), que se desplazan helicoidalmente a lo largo de las líneas de campo [37]. En la Figura 2-6 puede verse un esquema de un hipotético reactor de fusión basado en este tipo de confinamiento.



**Figura 2-6:** Visión esquemática de un reactor de fusión basado en confinamiento magnético: (A) Cámara de vacío; (B) Plasma; (C) Radiación del plasma; (D) Manto; (E) Producción de electricidad [38]

## 2.5. Confinamiento magnético

Como se ha visto en la sección 2.4, la idea básica del confinamiento magnético es la de confinar las partículas en un espacio pequeño por medio de campos magnéticos. Esto es factible debido al hecho de que las partículas del plasma que se quieren confinar están cargadas eléctricamente, de modo que un campo magnético puede ejercer una fuerza sobre ellas. Los dispositivos toroidales son los que han logrado los mejores rendimientos en confinamiento. Dentro de estos dispositivos destacan dos clases de dispositivos: el TOKAMAK y el STELLARATOR.

### 2.5.1. Stellarator

El stellarator (ver Figura 2-7) es un dispositivo toroidal de confinamiento magnético que fue propuesto por el astrofísico Lyman Spitzer en 1951 [39]. Los dispositivos de la clase stellarator no tienen simetría toroidal, y los campos

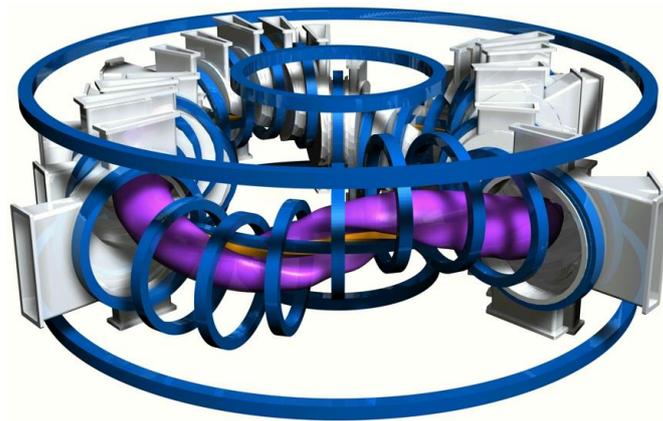
magnéticos necesarios para confinar el plasma son generados exclusivamente por bobinas externas, sin requerir una corriente eléctrica toroidal en el plasma. Esta característica hace que su confinamiento sea inherentemente estacionario, siempre que se mantengan las corrientes en las bobinas externas. Salvando estas diferencias, la física de los plasmas producidos en stellarators y tokamaks es similar.

Esta clase de dispositivos pueden ser de diferentes tipos, dependiendo de las configuraciones que adopten:

- **Torsatrón:** configuración con bobinas helicoidales continuas o bobinas discretas, produciendo campos similares.
- **Helioatrón:** configuración con una bobina helicoidal que se utiliza para confinar el plasma, junto con un par de bobinas de campo poloidal para proporcionar un campo vertical. Las bobinas de campo toroidal también se pueden usar para controlar las características de la superficie magnética.
- **Modular:** configuración con un conjunto de bobinas modulares (separadas) y una espiral toroidal torcida.
- **Heliac:** stellarator de eje helicoidal; configuración donde la complejidad de la geometría envuelve el campo magnético describiendo una trayectoria helicoidal. Habitualmente puede proporcionar más giro que el torsatrón o helioatrón, especialmente cerca del centro del plasma (eje magnético). El heliac original consiste solo en bobinas circulares y el heliaco flexible agrega una pequeña bobina helicoidal para permitir que el giro pueda variar por un factor de hasta 2.
- **Helias:** stellarator helicoidal avanzado; configuración que utiliza un juego de bobina modular optimizado y diseñado para alcanzar simultáneamente plasmas altos, bajas corrientes de Pfirsch-Schluter y buen confinamiento de partículas energéticas. El concepto del helias es el más prometedor para el desarrollo de futuros stellarators comerciales. El dispositivo Wendelstein 7-X se basa en una configuración de helias de cinco períodos de campo.

La ausencia de corrientes inducidas en el plasma es una gran ventaja para este tipo de dispositivos ya que permite un trabajo estacionario y con ausencia de disrupciones (inestabilidades que se producen por una pérdida del confinamiento del plasma que deberían evitarse). Adicionalmente, es posible una

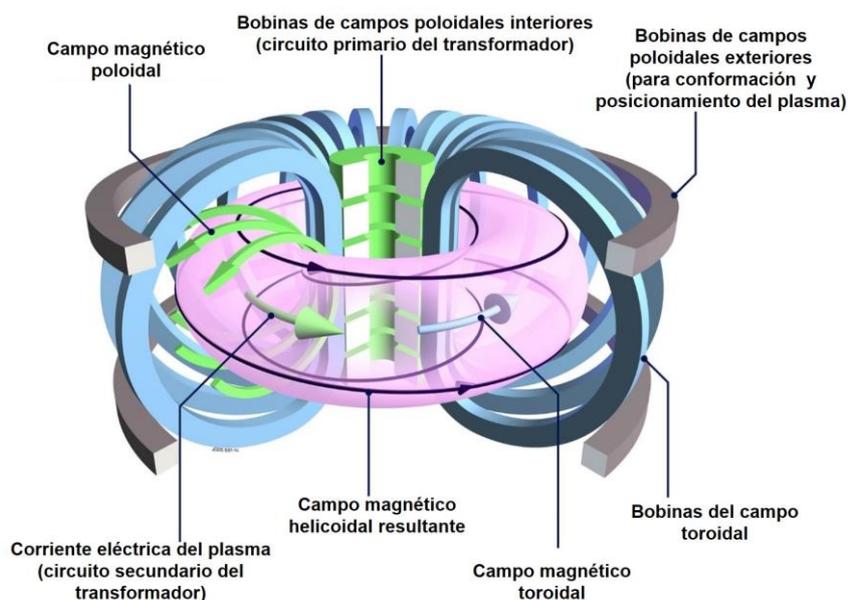
configuración muy diversa del dispositivo que permite un control del mismo mucho mejor que el que es posible con los dispositivos del tipo tokamak. Debido a que el diseño y la construcción de los stellarators es más complicado (las tolerancias son muy pequeñas, del orden de milímetros), su desarrollo ha ido siempre una generación por detrás de los tokamaks, no alcanzando el rendimiento de estos últimos.



**Figura 2-7:** Stellarator TJ-II. El plasma se representa en color fucsia. Se pueden apreciar las ventanas de observación para la diagnosis del plasma

## 2.5.2. Tokamak

El tokamak (Figura 2-8), propuesto por Tamm y Sajarov en 1951 [40], es el dispositivo con el que se han conseguido los mejores resultados en el campo de la investigación en fusión nuclear controlada.



**Figura 2-8:** Representación esquemática de un Tokamak. El plasma se presenta en color rosado

En estos dispositivos, una corriente toroidal es inducida a través del plasma por un solenoide central. Dicha corriente produce un campo magnético poloidal, cuyas líneas de campo circulan a través del plasma, siendo capaz de mantener el plasma confinado y proporcionar un equilibrio del balance de fuerzas. En la Tabla 2-1 se tienen las características principales de diferentes dispositivos tokamak.

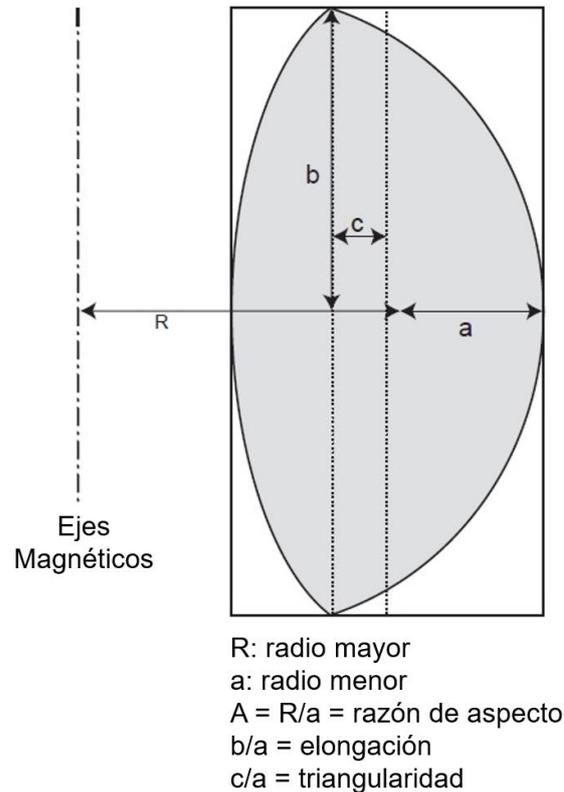
**Tabla 2-1:** Características de diferentes dispositivos tokamaks [41]

<b>Parámetros / Dispositivo</b>	<b>Alcator C-Mod</b>	<b>DIII-D</b>	<b>NSTX</b>
Localización	EEUU	EEUU	EEUU
Año	1991	1986	1999
R(m);R/a[range]	0,67;3,04	1,66;2,47	1;1,16
B(T)[range]	8	2,2	0,3
I(MA)[max]	2	3	1,4
Volumen Plasma(max, m <sup>3</sup> )	1	24	14
Longitud del pulso (sg)	5	25	3,5
Componentes expuestos al plasmas	Solid Mo y W	C	CFC <sup>7</sup> /Graphit, Li coating
<b>Parámetros / Dispositivo</b>	<b>ASDEX-U</b>	<b>FTU</b>	<b>JET</b>
Localización	Alemania	Italia	Reino Unido
Año	1991	1990	1983
R(m);R/a[range]	1,65;3,2	0,94;3,2	2,96;3,1
B(T)[range]	3,1	8	4
I(MA)[max]	2	1,6	6
Volumen Plasma(max, m <sup>3</sup> )	13	-	100
Longitud del pulso (sg)	10	1,7	60
Componentes expuestos al plasmas	C, W-coate	Limitadores Mo	C, Be, W-Coated
<b>Parámetros / Dispositivo</b>	<b>JT-60U</b>	<b>MAST</b>	<b>TCV</b>
Localización	Japón	Reino Unido	Suiza
Año	1985	1999	1992
R(m);R/a[range]	3,2;4	0,8;1,3	0,86;3,6
B(T)[range]	4,8	0,52	1,43
I(MA)[max]	5	1,4	0,8
Volumen Plasma(max, m <sup>3</sup> )	90	8	-
Longitud del pulso (sg)	10	1	2
Componentes expuestos al plasmas	C	C	C
<b>Parámetros / Dispositivo</b>	<b>KSTAR</b>	<b>EAST</b>	
Localización	Corea	China	
Año	2008	2006	
R(m);R/a[range]	1,8;3,6	1,9;4,2	
B(T)[range]	3,5	3,5	
I(MA)[max]	2	1	
Volumen Plasma(max, m <sup>3</sup> )	17,8	38	
Longitud del pulso (sg)	300	1000	
Componentes expuestos al plasmas	CFC/Grafito	CFC/Grafito	

<sup>7</sup> Carbono reforzado con fibra de carbono

## 2.6. Disrupciones

La configuración tokamak se presenta como una seria opción para el desarrollo de un futuro reactor. Sin embargo, se ve sometida con frecuencia a pérdidas abruptas del confinamiento del plasma llamadas disrupciones [42], [43].

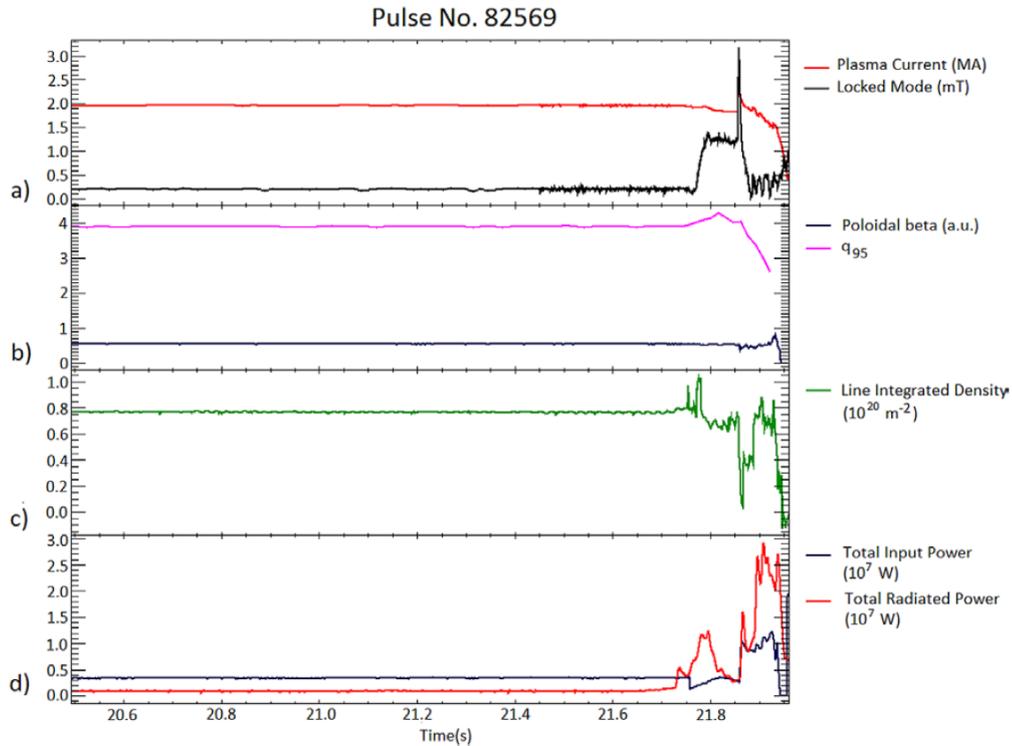


**Figura 2-9:** Sección transversal de un plasma de fusión tórico y sus principales características geométricas

Las disrupciones son un fenómeno plasmático descrito por primera vez por Gorbunov y Razumova en 1964 [44]. Actualmente, su aparición durante la operación es inevitable, especialmente en configuraciones de alto rendimiento. La necesidad de mitigar las consecuencias de este evento físico mediante su temprana detección será esencial en el tokamak de siguiente generación ITER [45]. En la Figura 2-9 se muestra la sección de diferentes características de un plasma de fusión tórico.

Estas repentinas pérdidas de confinamiento producen la interrupción de la descarga, además de afectar a la continuidad de la operación del dispositivo y pueden constituir un serio factor de riesgo para su integridad. Durante una disrupción, en períodos de tiempo del orden de milisegundos, el plasma excede sus límites operacionales con la resultante pérdida de energía y corriente. En la

Figura 2-10 se puede ver la evolución de una disrupción para diferentes magnitudes físicas del plasma.



**Figura 2-10:** Evolución en el tiempo de (a) corriente de plasma (rojo), amplitud de modo bloqueado (negro), (b) beta poloidal (azul),  $q_{95}$  (rosa), c) densidad integrada de línea medida por interferómetro, d) potencia de entrada total (azul) y potencia total radiada medida con bolómetro (rojo) para la disrupción JET-ILW N° 82569 [46]

Durante el proceso de disrupción es posible que se transfieran altas cargas térmicas a los componentes de la primera pared del dispositivo. Posteriormente, grandes corrientes son inducidas en la cámara de vacío y en las estructuras aledañas, provocando fuerzas capaces de causar daños considerables (por dar algún dato de referencia las fuerzas son equivalentes al peso de un Airbus A380, el mayor avión que existe en la actualidad). El desarrollo de un modelo teórico que permita comprender la física que subyace detrás de este fenómeno es intrínsecamente muy complejo debido al número de variables que intervienen y al comportamiento altamente no lineal del plasma. Actualmente solo se disponen de modelos teóricos parciales. Es por ello por lo que habitualmente se suelen utilizar modelos estadísticos basados en aprendizaje automático para intentar predecir su aparición. Es decir, modelos basados en datos.

La predicción de la disrupción depende de los sistemas de mitigación, que se basan en el final abrupto del calentamiento del plasma, el control de la corriente y la forma del plasma y la inyección de gas y de pastillas de terminación de la

fusión (*killer pellets*). El propósito de estos sistemas es mitigar el efecto de las disrupciones. En general, las disrupciones rápidas se han excluido de los trabajos que se han desarrollado en este campo y esto puede ser un problema grave porque, aunque estas disrupciones son infrecuentes, son igual de peligrosas que las otras.

La necesidad de mitigar las consecuencias de este evento físico mediante su temprana detección será esencial en el próximo tokamak ITER [45]. El uso de análisis estadísticos complejos basados en grandes bases de datos de disrupciones se han mostrado eficaces como predictores tempranos de este tipo de fenómeno en los sistemas de tiempo real de JET [31], [33].

### 2.6.1. Causas de las disrupciones

**Tabla 2-2:** Descripción del significado de las variables y los parámetros físicos utilizados

Parámetros	Descripción
$Z_{eff}$	Carga iónica efectiva del plasma
$R_0$	Radio mayor
$I_q$	Corriente del plasma
$a$	Radio menor
$B_\phi$	Campo magnético toroidal
$\beta$	Cociente entre la presión del plasma y la presión del campo magnético
$q_a, q$	Factor de seguridad de accidentes

Hay varias causas identificadas de disrupciones. Los límites de operación para una operación estable son impuestos tanto por disrupciones low- $q$ , como por disrupciones del límite de densidad. Estos dos límites operativos se pueden combinar en un diagrama que fue definido por Hugill [47]. En la Figura 2-11 se muestra la limitación del régimen operacional estable del tokamak en una región de  $(q_a, \bar{n})$  del espacio, donde  $q_a$  denota el factor de seguridad en el borde del plasma y  $\bar{n}$  denota la densidad media de electrones. En este diagrama, el régimen de operación se muestra como una función de  $1/q_a$ , que es proporcional a la corriente de plasma ( $I_p$ ) y al parámetro de Murakami  $\bar{n} R/B_\phi$ . Las "disrupciones low- $q$ " y las "disrupciones de límite de densidad" definen esta región. El régimen de operación se reduce para plasmas OH contaminados y se extiende más allá del límite  $Z_{eff} = 1$  cuando se emplea calefacción auxiliar. En la Tabla 2-2 se describe el significado de las variables y parámetros utilizados en esta sección.

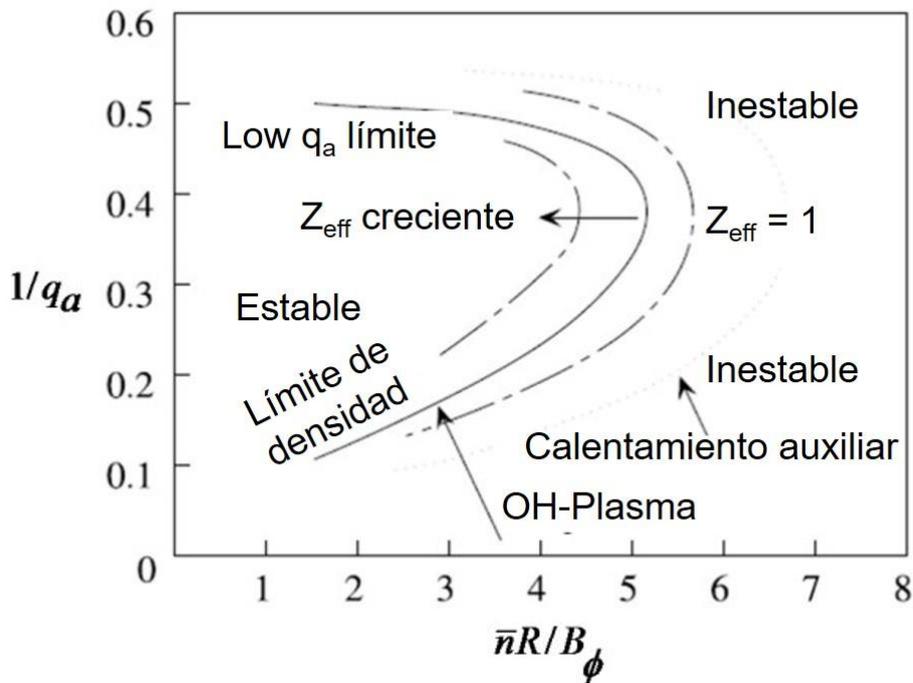


Figura 2-11: El diagrama de Hugill

#### 2.6.1.1. Disrupciones de límite de densidad

La densidad del plasma alcanzable en un tokamak es aproximadamente proporcional a la densidad de corriente toroidal. La densidad más alta alcanzable para una operación tokamak estable se conoce como 'densidad o límite de Murakami' [48]. Por encima de este límite, se producen disrupciones críticas en la densidad del plasma. Una fórmula empírica para esta densidad crítica en tokamaks es

$$\bar{n}_{crit} \approx 10^{20} B_{\phi} A_i^{1/2} / q_a Z_{eff} R_0 (m^{-3}) \quad \text{Ec. 2-5}$$

donde  $A_i = (\text{masa de iones}) / (\text{masa de protones})$ ,  $Z_{eff}$  es la carga iónica efectiva del plasma. El intento de aumentar la densidad mediante la inyección de gas conduce a un enfriamiento adicional del borde frío del plasma de alta densidad debido al aumento de la radiación. El enfriamiento está más localizado en el lado del campo alto, que se llama MARFE (multifaceted asymmetric radiation from the edge). En este proceso, la resistividad aumenta en el borde, la corriente toroidal se contrae y conduce a un perfil más pronunciado. En este escenario, el perfil de la corriente máxima puede desarrollar modos de rasgado (*tearing mode*) en superficies de flujo racional, formando islas magnéticas. Estas islas crecen y disparan mayores disrupciones en el plasma. El enfriamiento del plasma del borde, es decir, la

contracción del perfil de temperatura puede posponerse por calentamiento adicional, desplazando así el límite de densidad a valores más altos.

### 2.6.1.2. Disrupciones low- $q$

El factor de seguridad  $q$  es la relación entre el número de veces que una línea del campo magnético viaja alrededor del confinamiento toroidal desde la dirección toroidal a la poloidal. Si se quiere evitar inestabilidades el factor de seguridad debería ser  $q > 1$ . Se ha demostrado que determinados valores de low- $q$ , especialmente  $q = 2$ , son valores que juegan un rol fundamental en la estabilidad del plasma. Superficies magnéticas con  $q = 2$ , suelen conducir a inestabilidades que finalmente generan una disrupción.

### 2.6.1.3. Límite de beta o límite de disrupción del modo *ballooning*

Los modos *ballooning* son inestabilidades producidas por la presión. La superficie de flujo del plasma se abulta debido a las inestabilidades de modo *ballooning* que son creadas por la alta presión del plasma en el lugar donde la curvatura de los campos magnéticos es más pronunciada, como en las puntas de un plasma verticalmente alargado. Estas inestabilidades conducen a disrupciones y, por lo tanto, establecen un límite superior a la presión del plasma o a la  $\beta$  del plasma para una operación estable del tokamak. La estabilidad frente al *ballooning* depende de la magnitud de la curvatura y de la longitud de la conexión, la cual está relacionada con  $q$  y  $R_0/a$ . Para los plasmas circulares en un toro axisimétrico, una estimación teórica simplificada sería  $\beta \leq a/R_0q^2$  para la estabilidad.

## 2.6.2. Fases de las disrupciones

Tal y como se muestra en la Figura 2-12, en las disrupciones se pueden distinguir las siguientes fases [42], [43]:

1. **Fase inicial:** Un cambio en las condiciones del plasma produce una inestabilidad en el dispositivo que se traduce en un ligero aumento en la corriente y densidad del plasma. Estos cambios pueden ser debido tanto a factores externos, como fallos mecánicos o de operación, o factores internos procedentes de inestabilidades del plasma. En esta fase estos cambios son tan sutiles que apenas son detectables.
2. **Fase precursora:** los cambios en la configuración de inicio del plasma alcanzan un punto crítico debido a nuevas inestabilidades MHD crecientes y detectables. Si los fenómenos se detectan con el tiempo suficiente, se pueden

tomar medidas de mitigación para prevenir o reducir los efectos. Teóricamente, estas inestabilidades comienzan como islas magnéticas [49] girando alrededor del eje del plasma magnético, y crecen exponencialmente en decenas de milisegundos, que conducen a la disrupción [50].

3. **Fase rápida (apagado térmico):** en esta fase se aplanan el perfil de corriente radial y la temperatura central cae drásticamente en unos pocos milisegundos.
4. **Fase de enfriamiento (extinción de corriente):** la energía magnética del campo magnético poloidal se disipa como energía térmica. La transmisión de esta energía puede ser perjudicial para la integridad del dispositivo. El tiempo de decaimiento depende de las condiciones particulares y de la posición del plasma.

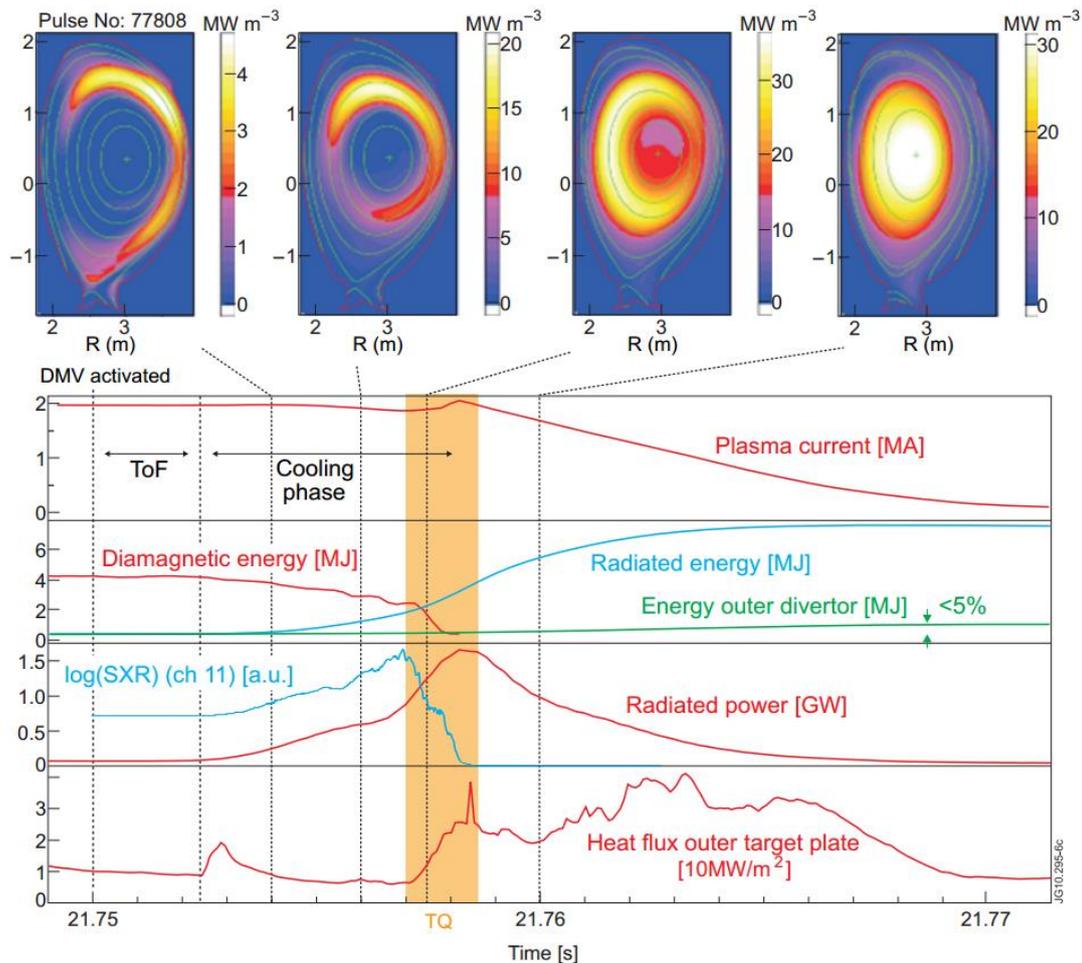


Figura 2-12: Secuencia de una disrupción.  $A_r/D_2$  inyección,  $p_{DMV} = 3,6MPa$

## 2.7. TJ-II y JET

En Madrid se encuentra en funcionamiento el stellarator más grande de Europa, el TJ-II. Es de tipo heliac flexible de tamaño medio [51], [52] y sus objetivos principales son el estudio del confinamiento y del transporte de energía y de partículas. La disposición de sus bobinas permite una gran variedad de configuraciones magnéticas, y un amplio rango de valores de transformada rotacional, siendo ésta su característica más especial, y que lo distingue de otros stellarators. Una característica destacable del TJ-II es que consigue el control efectivo de la transformada rotacional y la cizalladura magnética, lo que permite disponer de un amplio conjunto de configuraciones magnéticas.

Los primeros estudios sobre la configuración magnética del TJ-II se realizaron conjuntamente entre el laboratorio ORNL (Oak Ridge National Laboratory, EE.UU.) y el CIEMAT (Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas) [53], cuyo resultado fue el proyecto TJ-II, desarrollado por el CIEMAT [54] dentro del programa de fusión europeo. El TJ-II, incluyendo la cámara de vacío, las bobinas y la estructura que las soporta (Figura 2-7), tiene un diámetro de cinco metros, una altura de dos metros sobre el suelo de la plataforma experimental y un peso de sesenta toneladas, fabricado en acero de baja permeabilidad magnética (304 LN). A finales de 1997 se consiguieron las primeras descargas [55].

Los principales componentes del TJ-II son:

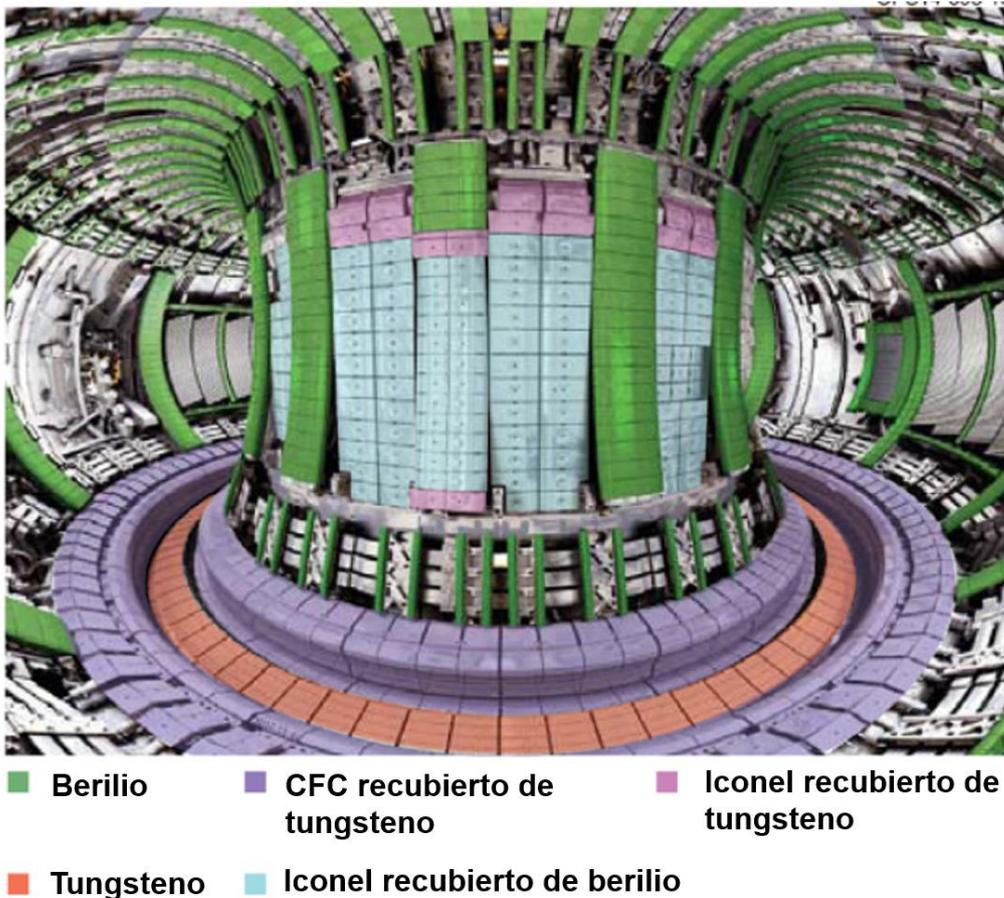
1. **Bobinas.** El campo magnético del TJ-II es generado por un conjunto de bobinas externas, que le confieren la configuración deseada. Cada bobina posee un número variable de vueltas, cuya corriente por vuelta depende del tipo de bobina y de la configuración magnética que se desee. El campo magnético producido puede alcanzar 1,2 Teslas. Todas las bobinas se refrigeran con agua que circula a través de orificios longitudinales en los conductores de cobre, y están embridadas por una estructura mecánica para evitar deformaciones.
2. **Cámara de vacío.** La cámara de vacío del TJ-II está constituida por ocho octantes iguales, que se diseñaron para aprovechar la simetría de los campos magnéticos del mismo. Además, cuenta con 92 ventanas de observación (Figura 2-7) para los diagnósticos del plasma, los sistemas de calentamiento y los de inyección de gas.
3. **Sistemas de calentamiento.** El TJ-II tiene instalados dos girotrones (generadores de microondas de alta potencia), sintonizados al segundo armónico de la resonancia ciclotrónica electrónica [56].

El **Joint European Torus (JET)**, situado en el centro para fusión nuclear de Culham, es el mayor y más potente tokamak del mundo además de ser el principal objetivo del programa europeo de investigación en fusión nuclear. Este dispositivo está diseñado para estudiar la fusión en las condiciones que serían necesarias en una planta de generación, siendo el único dispositivo que opera en la actualidad utilizando una mezcla de deuterio-tritio [57] como combustible, el cual será utilizado en los futuros reactores comerciales de fusión.

Desde que JET comenzó a operar en 1983, se han conseguido importantes avances en la ciencia e ingeniería de fusión, incrementando la confianza y la viabilidad del tokamak como modelo de construcción de futuras plantas de producción de energía [58].

En 1991, JET se convirtió en el primer dispositivo de confinamiento magnético para lograr la fusión nuclear: una mezcla Deuterio-Tritio con un 11% de Tritio proporcionó 1,7 MW de potencia de fusión [59]. Desde entonces se han utilizado pequeñas cantidades de tritio en 1997, cuando se alcanzó el récord mundial de 16 MW de potencia de fusión [60], y en 2003.

En 2005, la retención de tritio que se produjo en el divertor de carbono reforzado con fibra de carbono (CFC) de JET dejó en claro que, a pesar de la elevada capacidad de carga térmica elevada de este material, dichos materiales eran incompatibles con el inventario estrictamente controlado de tritio de ITER. Se decidió que una combinación diferente de materiales formaría la pared y el divertor de ITER, y que una versión de prueba de dicha pared se instalaría y probaría en JET [61]. Entre 2009 y 2011, JET estuvo fuera de servicio con el fin de permitir la instalación de una primera pared revestida de berilio en la cámara principal, CFC en los puntos de golpeo del divertor, y tungsteno para el resto del divertor. Esta combinación se conoce comúnmente como la pared de tipo ITER o ITER-ILW (ITER like wall) y es la que está actualmente en funcionamiento (ver Figura 2-13).



**Figura 2-13:** Fotografía de JET ITER-Like Wall (ILW). El sombreado de colores indica el material de cada componente [62]

Junto con la mejora de la potencia de calentamiento, este ITER-LikeWall permite a los científicos desarrollar escenarios de plasma que se asemejan lo más posible a los previstos para ITER [63]. Ya los experimentos JET han ayudado a ITER a tomar la decisión de comenzar a operar con un divertor completo de tungsteno, lo que reduce sustancialmente los costes de inversión. Estos escenarios enfocan su atención muy especialmente al ELM (Edge Localized Mode) [64] y la mitigación de las disrupciones [65].

## 2.8. ITER

ITER ("El Camino" en latín) es actualmente el proyecto energético más ambicioso del mundo actual. Puede verse una recreación de esta instalación en la Figura 2-14.

En el sur de Francia, 35 naciones colaboran para construir el tokamak más grande del mundo, un dispositivo de fusión magnética que ha sido diseñado para demostrar la viabilidad de la fusión como una fuente de energía a gran escala y

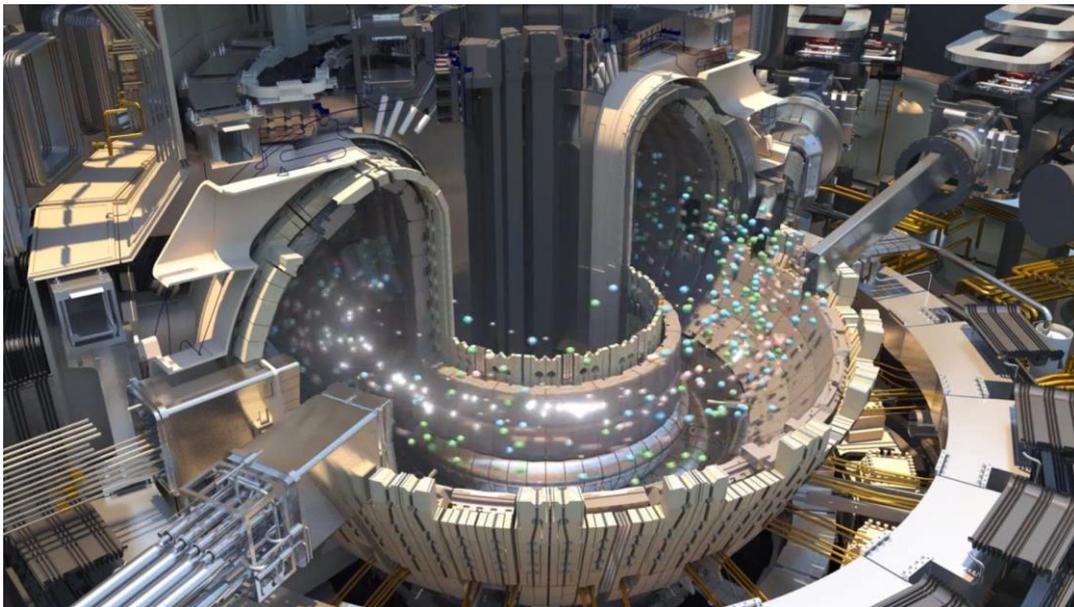
libre de carbono.

La campaña experimental que se llevará a cabo en ITER es crucial para hacer avanzar la ciencia de la fusión y preparar el camino para las plantas de energía de fusión del mañana.

ITER tendrá varios objetivos [66]:

- 1. Producción de 500 MW de potencia de fusión.** El récord mundial de energía de fusión lo tiene actualmente el JET tokamak europeo. En 1997, JET produjo 16 MW de potencia de fusión con una potencia de entrada total de 24 MW ( $Q = 0,67$ ). ITER está diseñado para producir un rendimiento de diez veces la energía ( $Q = 10$ ), o 500 MW de potencia de fusión con una potencia de entrada de 50 MW. ITER no capturará la energía que produce como electricidad, como el primer experimento de fusión en la historia en producir ganancia neta de energía, sino que preparará el camino para la siguiente máquina que pueda hacerlo.
- 2. Demostrar el funcionamiento integrado de las tecnologías para una central de fusión.** ITER cubrirá la brecha entre los actuales dispositivos de fusión experimental de menor escala y las centrales de fusión del futuro. Los científicos podrán estudiar plasmas en condiciones similares a las esperadas en una futura central eléctrica y tecnologías de prueba tales como calefacción, control, diagnóstico, criogenia y mantenimiento remoto.
- 3. Conseguir un plasma de deuterio-tritio en el que la reacción se mantiene a través del calentamiento interno.** La investigación de la fusión está hoy en el umbral de explorar un *plasma ardiente* (burning plasma), en el cual el calor de la reacción de fusión se confina dentro del plasma el tiempo suficiente para que la reacción se mantenga durante un periodo largo. Los científicos confían en que los plasmas de ITER no sólo producirán mucha más energía de fusión, sino que se mantendrán estables durante períodos de tiempo prolongados. Se estima que las descargas puedan durar entre 30 y 40 minutos frente a los 40 segundos que duran en JET.
- 4. Prueba de generación de tritio.** Una de las misiones para las etapas posteriores de la operación del ITER es demostrar la viabilidad de producir tritio dentro del recipiente de vacío. El suministro mundial de tritio (utilizado con el deuterio para alimentar la reacción de fusión) no es suficiente para cubrir las necesidades de futuras centrales eléctricas. ITER proporcionará una oportunidad única para probar en el recipiente el manto fértil (*Breeding Blanket*) de generación de tritio en un ambiente de fusión real.

5. **Demostrar las características de seguridad de un dispositivo de fusión.** ITER alcanzó un hito importante en la historia de la fusión cuando, en 2012, la organización ITER obtuvo la licencia de operador nuclear en Francia sobre la base del examen riguroso e imparcial de sus ficheros de seguridad. Uno de los principales objetivos de la operación del ITER es demostrar el control del plasma y las reacciones de fusión, todo ello siendo respetuosos con el medio ambiente.



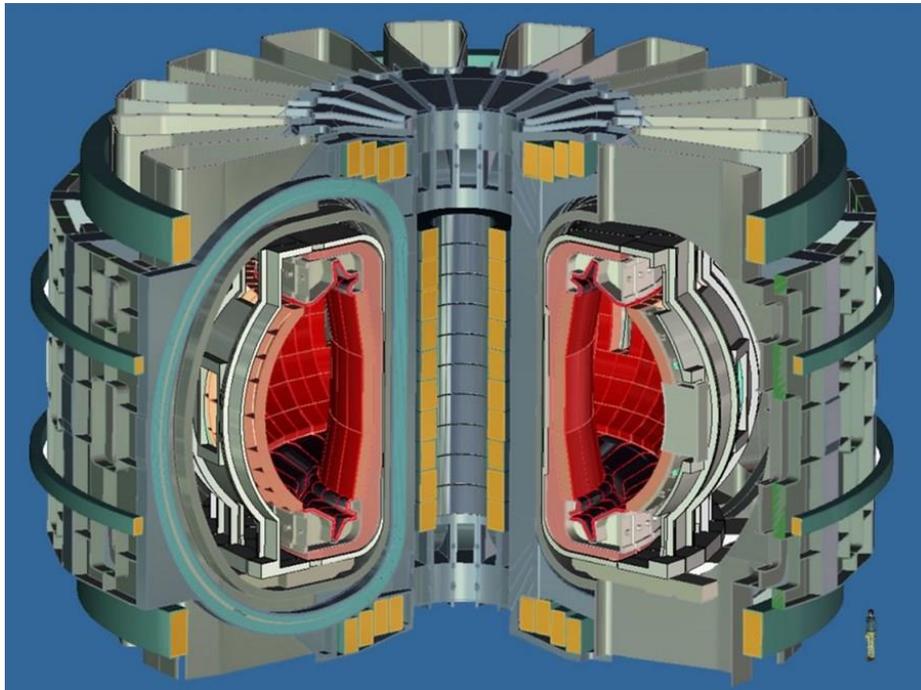
**Figura 2-14:** Recreación de ITER. Fuente: Jamison Daniel, Oak Ridge Leadership Computing Facility

## 2.9. DEMO

DEMO es la máquina que llevará la investigación de la energía de fusión al umbral de un prototipo de reactor de fusión [67]. Después de ITER, la máquina que demostrará la viabilidad tecnológica y científica de la energía de fusión, DEMO abrirá el camino a su explotación industrial y comercial.

El término DEMO es en realidad una serie de fases, más que una sola máquina. Por el momento, los diferentes proyectos conceptuales de DEMO están siendo considerados por todos los miembros de ITER (China, la Unión Europea, India, Japón, Corea, Rusia y, en menor medida, los Estados Unidos). Es demasiado pronto para decir si DEMO será una colaboración internacional, como ITER, o una serie de proyectos nacionales. ITER se plantea fundamental para el éxito de DEMO ya que las enseñanzas que se obtengan en este proyecto serán fundamentales para los físicos e ingenieros que tengan la responsabilidad de

desarrollar el proyecto DEMO.



**Figura 2-15:** Aunque el calendario, las especificaciones técnicas y el nivel de determinación varían de un miembro a otro, el objetivo es el mismo para todos: construir la máquina que demuestre la obtención de electricidad de fusión a escala industrial para 2050. Ejemplo conceptual de una futura máquina DEMO [67]

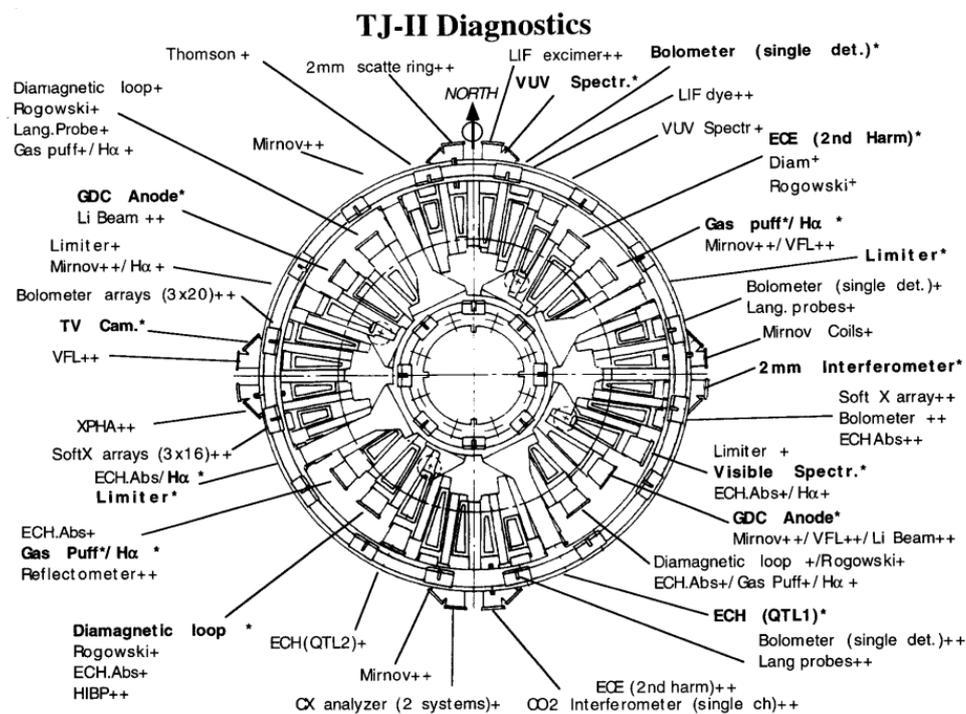
Respecto a cómo será la futura máquina DEMO, todos los diseños conceptuales dibujan una máquina que es más grande que ITER. El radio grande ("R") de la sección transversal del plasma, que determina el tamaño de la máquina, oscila entre 6 y 10 metros. En comparación, la "R" del ITER mide 6.2 metros y la del tokamak más grande en operación, JET, mide la mitad.

La energía que producirá varía desde 500 MW para la demostración europea, hasta 1500 MW para la DEMO japonesa. (Una máquina de 1500 MW sería el equivalente práctico de un reactor de fisión de próxima generación del tipo EPR que se está construyendo en Flamanville, Francia u Olkiluoto, Finlandia).

Para algunos Miembros, DEMO será un reactor de demostración preindustrial; para otros, será un cuasi-prototipo que no requiere más pasos experimentales antes de la construcción de un reactor de fusión a escala industrial. La Figura 2-15 muestra un ejemplo conceptual de una futura máquina DEMO.

## 2.10. Diagnosis

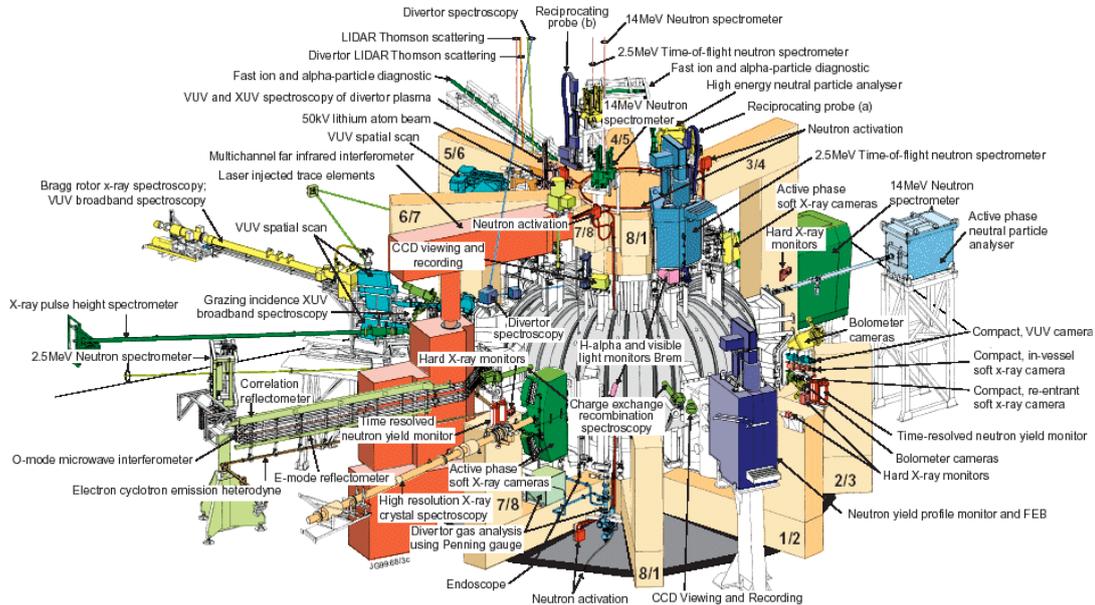
El principal objetivo de la diagnosis del plasma es deducir información de su estado a partir de observaciones experimentales de los procesos físicos y efectos asociados que en él se producen. Para conseguir un rendimiento científico óptimo, se dispone de un conjunto de diversos diagnósticos con el que se pueden determinar las características fundamentales del plasma producido. La Figura 2-16 muestra los principales elementos de diagnosis del TJ-II [68]. Del mismo modo se muestran los diagnósticos de JET en la Figura 2-17 [57]. Estos diagnósticos se encargan de generar terabytes de datos que serán incluidos en bases de datos masivas para su posterior análisis mediante las técnicas y arquitecturas hardware y software descritas en el capítulo 1.



**Figura 2-16:** Localización y representación esquemática de los principales diagnósticos del stellarator TJ-II [68]

La investigación sobre la fusión nuclear por confinamiento magnético se centra en mantener el plasma confinado a alta densidad,  $O(10^{21} \text{ m}^{-3})$  y alta temperatura,  $O(10 \text{ keV})$  el mayor tiempo posible. La acción conjunta de los diversos sistemas técnicos de un dispositivo de fusión nuclear (fuentes de alimentación, sistemas de calefacción, bobinas de campo magnético, sistema de inyección de gas y sistema de control) determina un período de tiempo durante el cual el plasma es creado, vive y finalmente muere. Este período de tiempo se llama *descarga*. Actualmente existen algunos modelos físicos para describir los plasmas de alta

temperatura, pero no son capaces de explicar completamente la evolución y el comportamiento de los plasmas cercanos a condiciones termonucleares.



**Figura 2-17:** Localización y representación esquemática de los principales diagnósticos del tokamak JET

Debido a la falta de modelos teóricos y físicos para describir y pronosticar el comportamiento del plasma, la actividad investigadora en dispositivos de fusión se dedica a medir la mayor cantidad posible de propiedades del plasma con el fin de conocer su naturaleza. No obstante, medir diferentes características del plasma no es una tarea sencilla. En primer lugar, se debe tener en cuenta que los dispositivos de fusión dan un acceso limitado a los diagnósticos. En segundo lugar, es importante enfatizar que, debido a las altas temperaturas del plasma, O (108 K), las medidas se obtienen por métodos indirectos. El plasma puede emitir tanto radiación (en todos los rangos, desde microondas hasta rayos gamma) como partículas. Cada diagnóstico está optimizado para medir una cantidad específica. Los diagnósticos convierten sus observaciones en señales eléctricas, pero estos datos sin procesar deben tratarse con algoritmos de inversión, que pueden ser complejos, antes de obtener cantidades físicas.

Hasta ahora, la mayoría de los diagnósticos solo proporcionan datos sin procesar en tiempo real y no las medidas físicas. Son varios los factores que influyen en este caso, por ejemplo, necesidad de preprocesamiento de datos y necesidad de entradas de otros diagnósticos, y requisitos de validación de datos. Por lo tanto, los datos sin procesar se almacenan en la base de datos del dispositivo de fusión para su *análisis diferido* (off-line). El término *análisis diferido* tiene un doble

significado. Por un lado, significa procesar los datos en bruto y convertirlos en datos procesados (cantidades físicas). Por otro lado, también se refiere a los estudios globales del plasma a partir de datos tanto sin procesar como procesados.

La base de datos de un dispositivo de fusión contiene todos los datos sin procesar y todos los datos procesados del dispositivo. La base de datos está formada por señales, donde una señal puede ser una serie de tiempo/amplitud, datos con resolución temporal y espacial (típicamente, son la evolución temporal de perfiles como la temperatura o la densidad de los electrones) y videos. Con respecto a los videos, debe tenerse en cuenta que, en la actualidad, las videocámaras son muy comunes para fines de diagnóstico. Hay cámaras que son sensibles a la emisión de plasma infrarrojo y se utilizan para detectar puntos calientes durante una descarga en ejecución. Otro tipo de cámaras son sensibles al rango visible y están dedicadas, por ejemplo, a analizar la turbulencia en el borde del plasma.

En la fusión nuclear, un primer paso en el análisis de datos es la inspección visual de las señales. La razón de esto reside en el hecho de que los diagnósticos producen los mismos patrones morfológicos en las señales para comportamientos plasmáticos reproducibles. Por lo tanto, la simple inspección visual de las señales es útil para la ubicación temporal de los eventos de plasma durante una descarga.

Las evoluciones de señales suaves revelan que el plasma evoluciona de manera estable. Sin embargo, variaciones más o menos abruptas en las señales (por ejemplo, en amplitud, ruido o presencia / supresión repentina de patrones con estructura periódica) evidencian la aparición de algún tipo de cambio en la evolución del plasma. Estos cambios pueden aparecer como resultado del funcionamiento normal (por ejemplo, entrada de energía adicional, inyección de gas, transiciones de confinamiento, final del calentamiento auxiliar o métodos de diagnóstico perturbativo) pero también como una reacción al desarrollo de inestabilidades del plasma. Estas últimas son perturbaciones inesperadas que son consecuencia de una interdependencia altamente no lineal entre muchos fenómenos plasmáticos y entre el plasma y las estructuras circundantes. Está claro que para poner en funcionamiento una central eléctrica de fusión, idealmente, todas las posibles inestabilidades mencionadas anteriormente tienen que ser gestionadas por el sistema de control del dispositivo o, al menos, sus posibles efectos dañinos deben minimizarse.

# 3. FUNDAMENTOS TEÓRICOS Y ESTADO DEL ARTE

---

*“La práctica debe siempre ser edificada sobre la buena teoría”*

*-Leonardo Da Vinci-*

## 3.1. Definición de eventos

La detección de anomalías ha sido identificada como una técnica importante para detectar eventos críticos en un amplio rango de dominios donde la mayoría de los datos se consideran "normales" y poco interesantes [69] [70]. Sin embargo, es un concepto bastante difuso y los expertos en el dominio pueden tener nociones diferentes de lo que constituye una anomalía [71]. En el mundo académico, a menudo las siguientes definiciones se asemejan a sinónimos de detección de patrones anómalos: valores anómalos, anomalías, observaciones discordantes, excepciones, fallos, defectos, aberraciones, ruido, errores, daños, sorpresa, novedad, peculiaridades o contaminantes en diferentes áreas de aplicación. Sin embargo, los métodos y algoritmos utilizados en la práctica son habitualmente los mismos [70]. En la comunidad estadística, los conceptos de valores anómalos y detección de valores anómalos son conocidos desde hace mucho tiempo. En [72] se define un valor anómalo en un conjunto de datos como “[...] una observación (o un subconjunto de observaciones) que parece ser inconsistente con el resto de ese conjunto de datos”. En [73] hay una definición similar de un valor atípico: “[Un valor anómalo...] es una observación que se desvía tanto de otras observaciones que suscita la sospecha de que fue generada por un mecanismo diferente”.

En este trabajo se usará indistintamente el término evento y anomalía.

## 3.2. Retos en la detección de eventos

Varios factores hacen que no sea tarea sencilla definir una solución para la detección de eventos [70]:

1. Definir una región normal que abarque todos los posibles comportamientos normales es muy difícil.
2. Muchas veces el comportamiento normal continúa evolucionando y una

idea existente de comportamiento normal puede no ser suficientemente representativa en el futuro.

3. El límite entre el comportamiento normal y el periférico es a menudo difuso. Así, una observación periférica que se encuentra cerca de la frontera puede ser realmente normal y viceversa.
4. La noción exacta de un anómalo es diferente para dominios de aplicación diferentes. Cada dominio de aplicación impone un conjunto de requisitos y restricciones que dan lugar a una formulación de problemas específicos para la detección de valores anómalos.
5. La disponibilidad de datos etiquetados para entrenamiento y validación es a menudo un problema importante al desarrollar una técnica de detección de valores anómalos.
6. En varios casos en que los valores anómalos son el resultado de acciones maliciosas, los adversarios maliciosos se adaptan a hacer que las observaciones externas aparezcan como normales, haciendo más difícil la tarea de definir el comportamiento normal.
7. A menudo, los datos contienen ruido que es similar a los valores anómalos reales y por lo tanto es difícil de distinguir y eliminar.

### **3.3. Datos de entrada**

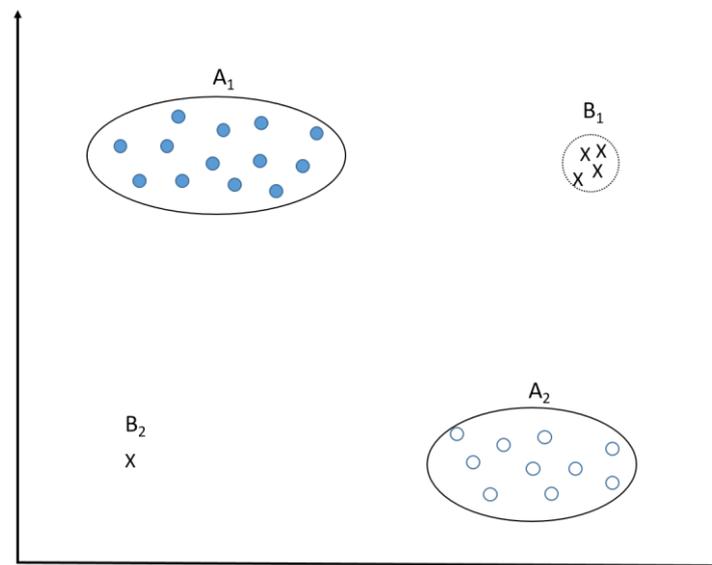
La entrada se trata generalmente como una colección de objetos de datos o instancias de datos [74]. Cada instancia puede ser descrita usando un conjunto de atributos y estos atributos pueden ser de diferentes tipos: binario, categórico o continuo.

Un punto clave para cualquier técnica de detección de eventos es identificar o construir el mejor conjunto de variables características, que permitan al algoritmo dar el mejor resultado en términos de ajuste y eficiencia computacional. En [75] y [76] se indican posibles métodos para lo comentado.

Para el caso de datos secuenciales, las instancias de datos tienen un orden definido de tal manera que cada instancia de datos ocurre secuencialmente en todo el conjunto de datos. Los datos de series temporales son el ejemplo más popular para este caso y se ha analizado extensamente con respecto a la detección de valores anómalos [77], [78].

### 3.4. Tipos de anomalías

En la Figura 3-1 puede verse un ejemplo de anomalías en un conjunto de datos bidimensional.  $A_1$  y  $A_2$  son dos regiones *normales*.  $B_1$  representa una región anómala y  $B_2$  un dato anómalo.



**Figura 3-1:** Un ejemplo de anomalías en un conjunto de datos bidimensional.  $B_1$  y  $B_2$  representan valores anómalos

Las anomalías pueden clasificarse según el número de instancias de datos consideradas como valores anómalos, en anomalías puntuales y anomalías colectivas [79]:

1. **Anomalías puntuales.** Se denomina como tal a aquella instancia de datos anómalo individual. Este es el tipo más simple y es el foco de la mayoría de los esquemas existentes de detección de valores anómalos [70]. En la mayoría de los casos, los datos se representan en vectores como en las bases de datos relacionales donde cada tupla contiene un número específico de atributos. El principio que suele subyacer a los métodos de detección de anomalías puntuales dentro de un conjunto de datos de tipo vector es cuantificar, a través de algunas métricas de extrañeza, cuánto se desvía esta métrica del dato anómalo del resto del conjunto de datos no considerados anómalos.
2. **Anomalías colectivas.** Una anomalía colectiva representa una colección de instancias de datos que está aislada o lejana con respecto a todo el conjunto de datos. La instancia de datos individuales en una anomalía colectiva puede no ser atípica por sí misma, pero la aparición conjunta como una colección es anómala [70]. Normalmente, las instancias de datos en una anomalía colectiva

están relacionadas entre sí. Una típica anomalía colectiva son las anomalías de secuencia, donde los datos están en el formato de una secuencia ordenada, habitualmente en lo que se denomina flujo de datos.

Los valores anómalos también se pueden clasificar dependiendo de los tipos de datos de entrada [79] de la siguiente forma:

1. **Vectoriales.** Los valores anómalos vectoriales se detectan a partir de la representación vectorial de datos tal y como hacen las bases de datos relacionales. Los datos se presentan en tuplas y cada tupla tiene un conjunto de atributos asociados. El conjunto de datos puede contener sólo atributos numéricos, atributos categóricos o ambos. Según el número de atributos, el conjunto de datos se clasifica en general como datos de baja dimensión y datos de alta dimensión, aunque no hay un corte claro entre estos dos tipos de conjuntos de datos. Dado que las bases de datos relacionales todavía representan el modelo principal para el almacenamiento de datos, este es el tipo más común de valores anómalos con los que se suele trabajar.
2. **Secuenciales.** En muchas aplicaciones, los datos se presentan como una secuencia. Un buen ejemplo de una base de datos de secuencia es el registro de llamadas del sistema informático donde se almacenan los comandos de ordenador ejecutados, en un cierto orden (log de comandos). Una secuencia de comandos en este registro puede tener la siguiente secuencia: http-web, buffer-overflow, http-web, http-web, smtpmail, ftp, http-web, ssh. La secuencia de órdenes puede indicar un comportamiento potencialmente malicioso que puede comprometer la seguridad del sistema. Con el fin de detectar secuencias de comandos anormales, las secuencias de comandos normales se mantienen y aquellas secuencias que no coinciden con ninguna secuencia normal son etiquetados como anómalos de secuencia. Los valores anómalos de la secuencia son una forma de valores anómalos colectivos.
3. **Trayectorias.** Recientes mejoras en los satélites y las instalaciones de rastreo han hecho posible recoger una gran cantidad de datos de trayectoria de objetos en movimiento. Los ejemplos incluyen datos de posicionamiento de vehículos, datos de seguimiento de huracanes y datos de movimiento de animales [80]. A diferencia de un vector o una secuencia, una trayectoria es normalmente representada por un conjunto de características clave que describen el movimiento, incluyendo las coordenadas de los puntos inicial y final; los valores medios, mínimos y máximos del vector direccional; y las velocidades media, mínima y máxima. Con estos datos se define una función de suma ponderada de la distancia con la que calcular la diferencia de trayectoria [81]. Los valores anómalos de la trayectoria pueden ser anómalos

puntuales si se considera cada trayectoria como una unidad básica de datos. Sin embargo, si se consideran los objetos en movimiento en la trayectoria, entonces una secuencia anormal de tales objetos en movimiento (que constituyen la subtrayectoria) es un valor atípico colectivo.

4. **Gráficos.** Representan aquellas entidades gráficas que son anormales en comparación con sus pares. Las entidades gráficas que pueden ser anómalas incluyen nodos, aristas y subgrafos. Por ejemplo, en [82] y [83] investigaron la detección de nodos anómalos en un gráfico bipartito. Los valores anómalos del gráfico pueden ser anomalías puntuales (por ejemplo, valores anómalos de nodo y borde) o anomalías colectivas (por ejemplo, valores anómalos de subgrafos).

A lo largo del trabajo que aquí se presenta se hablará siempre de métodos de detección de anómalos o eventos en anomalías puntuales y en datos de tipo vectorial.

### **3.5. Estado del arte**

Varias soluciones estadísticas o basadas en aprendizaje automático para la detección de cambios han sido propuestas y desarrolladas. A continuación, se analizan las más destacadas partiendo de una primera clasificación que toma el criterio de si la solución es de aplicabilidad a conjuntos de datos de baja o alta dimensionalidad.

### **3.6. Métodos de detección de anómalos para datos de baja dimensionalidad**

Esta clase de detectores corresponde principalmente a los primeros trabajos de este tipo que solían ser sobre conjuntos de datos estáticos y de pocos atributos (baja dimensionalidad). Se puede clasificar este tipo de detectores en 4 categorías principales: basados en estadísticas, distancias, densidad y clustering.

#### **3.6.1. Métodos de detección estadística**

Los métodos estadísticos de detección de valores anómalos [72], [73] se basan en los enfoques estadísticos que asumen un modelo de distribución o probabilidad que se ajustan al conjunto de datos dado. Bajo la distribución asumida, los valores anómalos son aquellos datos que no concuerdan con el modelo subyacente de los datos. Los métodos estadísticos de detección de valores anómalos pueden

clasificarse ampliamente en dos categorías: métodos paramétricos y métodos no paramétricos. Las principales diferencias entre estas dos clases de métodos radican en que los métodos paramétricos asumen la distribución subyacente de los datos dados y estiman los parámetros del modelo de distribución a partir de dichos datos [84], mientras que los métodos no paramétricos no asumen ningún conocimiento de distribución [85]. Los métodos estadísticos de detección de valores anómalos, paramétricos y no paramétricos suelen tener dos fases:

1. **Fase de entrenamiento.** consiste principalmente en ajustar un modelo estadístico o construir perfiles de datos basados en los datos disponibles.
2. **Fase de test.** Determina si una instancia de datos dada es un outlier con respecto al modelo o no.

#### 3.6.1.1. Métodos paramétricos

Los métodos paramétricos de detección de valores anómalos asumen explícitamente un modelo de distribución para el conjunto de datos dado (habitualmente la distribución normal o Gaussiana). Los parámetros del modelo de distribución supuesto se estiman usando los datos de la muestra. Los principales métodos paramétricos de detección de valores anómalos incluyen los métodos basados en la distribución Gaussiana [86], [87], [88] y de regresión [77], [78], [89], [90].

#### 3.6.1.2. Métodos no paramétricos

Las técnicas de detección de valores anómalos en esta categoría no hacen ninguna suposición sobre la distribución estadística de los datos. Los enfoques más populares son los histogramas basados en la frecuencia de los datos [91], [84], [92] y los métodos de la función de densidad del kernel. Este último método también es conocido como estimación de la ventana de Parzen [93]. Este método incluye el uso de la función kernel para aproximar la función de densidad de probabilidad (pdf – probability density function) de los datos disponibles. Una nueva instancia de datos que *caiga* en un área de baja pdf será clasificada como dato anómalo. Las funciones de kernel han sido utilizadas, por ejemplo, para la detección de valores anómalos en redes de sensores [94], [95].

#### 3.6.1.3. Ventajas y desventajas de los métodos estadísticos

Las principales ventajas y desventajas de este tipo de modelos son las siguientes [79]:

### **Modelos paramétricos**

Las ventajas de este tipo de métodos son:

1. Están justificados matemáticamente.
2. Si se da un modelo probabilístico, los métodos son muy eficientes y es posible discernir el significado de los valores anómalos encontrados.
3. Es posible detectar valores anómalos sin almacenar los conjuntos de datos originales que son, generalmente, de tamaños grandes.

Como desventajas se pueden mencionar las siguientes:

1. Hacen muchas suposiciones, siendo la más importante la asunción de que los datos se suelen distribuir de una forma determinada (habitualmente de forma normal).
2. En particular los métodos paramétricos, no se aplican en un escenario multidimensional porque la mayoría de los modelos de distribución se aplican habitualmente al espacio de características univariante.
3. Son inadecuados incluso para conjuntos de datos multidimensionales moderados. Esto limita enormemente su aplicabilidad, ya que en la mayoría de las aplicaciones prácticas los datos son múltiples o incluso de alta dimensionalidad.

### **Modelos no paramétricos**

Las ventajas de este tipo de métodos son:

1. No tienen los problemas asociados a la asunción de una distribución estadística concreta, lo que les permite trabajar, por ejemplo, con flujos de datos de baja dimensionalidad.
2. Efectivos para datos de baja dimensionalidad.

En cuanto a las desventajas:

1. Los histogramas carecen de la capacidad de tratar múltiples variables simultáneamente, lo que les hace inviables para el tratamiento de datos multidimensionales
2. Las funciones de kernels son computacionalmente muy costosas para el tratamiento de datos multidimensionales. Esta limitación los hace, en la

práctica, muy difíciles de aplicar a casos reales de tratamiento de flujos de datos de alta dimensionalidad.

### 3.6.2. Métodos basados en distancias

La mayoría de las métricas utilizadas para las técnicas de detección de valores anómalos basados en la distancia, se definen en base a los conceptos de vecindad local o  $k$  vecinos más cercanos (kNN - k-Nearest Neighbors) de los puntos de datos. La noción de valores anómalos basados en la distancia no asume ninguna distribución de datos subyacente y generaliza muchos conceptos a partir de métodos basados en la distribución. Además, los métodos basados en la distancia se adaptan mejor al espacio multidimensional y pueden calcularse mucho más eficientemente que los algoritmos basados en métodos estadísticos [79]. Normalmente, es necesario un tratamiento previo de los datos con el fin de normalizar las diferentes escalas de las variables de los datos antes de realizar la detección de valores anómalos.

#### 3.6.2.1. Vecindad local

La primera aproximación de detección de valores anómalos basados en la distancia, llamada  $DB(k, \ell)$ -Outlier, se debe a [96]. Seguidamente se muestra su definición.

**Definición:** Un punto  $p$  en un conjunto de datos es un  $DB(k, \ell)$ -Outlier, con respecto a los parámetros  $k$  y  $\ell$ , si no más de  $k$  puntos en el conjunto de datos están a una distancia  $\ell$  o menos (es decir, vecindad) de  $p$ .

#### 3.6.2.2. Distancia kNN

También han existido algunos métodos de detección de valores anómalos basados en la distancia que utilizan los  $k$  vecinos más cercanos (kNN) para medir el grado de anomalía de cada punto en el conjunto de datos.

Recientemente se ha propuesto una extensión de la noción de kNN, llamada: Grid-ODF (Grid Outlying Degree Factor), de los  $k$  objetos más cercanos a las  $k$  regiones densas más cercanas [97]. Este método emplea la suma de las distancias entre cada punto de datos y sus  $k$  regiones densas más cercanas para clasificar los puntos de datos. Esto permite que el algoritmo mida la anomalía de puntos de datos desde una perspectiva más global.

### 3.6.2.3. Ventajas y desventajas de los métodos basados en distancias

Tal y como se comenta en [79], las principales ventajas de estos métodos son:

1. No son paramétricos y no dependen de ninguna distribución asumida previamente para ajustarse a los datos.
2. Los valores anómalos se basan en distancias fáciles de entender e implementar.

Los inconvenientes que presentan son los siguientes:

1. La mayoría de ellos no son efectivos en el espacio de alta dimensión.
2. Los datos de alta dimensión en aplicaciones reales tienen mucho ruido y las desviaciones no normales pueden estar embebidas en algunos subespacios de menor dimensión que no pueden ser observados en el espacio de datos completo.
3. Las definiciones de vecindad local, independientemente del vecindario circular o de los  $k$  vecinos más próximos, no tienen mucho sentido en el espacio de alta dimensión.

### 3.6.3. Métodos basados en densidad

Este tipo de métodos, por lo general, implica investigar no sólo la densidad local del punto estudiado, sino también las densidades locales de sus vecinos más cercanos. Por lo tanto, la métrica de anomalía de una instancia del conjunto de datos, se refiere a una medida que compara una ratio de densidad de este punto contra las densidades promediadas de sus vecinos más cercanos. Los métodos basados en la densidad presentan una capacidad de modelado más fuerte de los valores extremos, pero tienen un coste computacional más alto.

#### 3.6.3.1. LOF (Local Outlier Factor)

Un esquema de formulación basado en la densidad de anómalos se ha propuesto en [98], el cual es más robusto que los métodos de detección de valores anómalos basados en distancias.

El procedimiento para aplicar este método sería:

1. Por cada punto, calcular la densidad de su vecindario local.

2. Calcular el LOF de un ejemplo  $p$  como la media de los cocientes de la densidad del ejemplo  $p$  y la densidad de vecinos más cercanos (kNN).
3. Los puntos con mayor valor LOF se consideran anómalos.

La densidad se suele considerar mediante dos parámetros:

1. MinPts que especifica el número mínimo de objetos.
2. Volumen. En este caso se sustituirá este parámetro por el valor  $reach - dist_{MinPts}(p, o)$  para  $o \in N_{MinPts}(p)$  como medida del volumen.

Seguidamente se define el método LOF

$$LOF(p) = \frac{1}{MinPts} \sum_0 \frac{lrd(o)}{lrd(p)} \quad \text{Ec. 3-1}$$

Dónde

$$lrd(p) = \frac{MinPts}{\sum_0 reach_{dist_{MinPts}}(p, o)} \quad \text{Ec. 3-2}$$

$$reach - dist(p, o) = \max\{k - distancia(o), d(p, o)\} \quad \text{Ec. 3-3}$$

$k$ -distancia sería la distancia a los  $k$ -enésimos vecinos más cercanos para cada punto  $p$ .

En la Figura 3-2 se muestra un conjunto de datos donde  $G_1$  y  $G_2$  representan dos grupos de datos de diferente densidad. Adicionalmente están los datos  $P_1$  y  $P_2$  que, según [73], pueden definirse como anómalos. Por el mismo criterio anterior se considera que  $G_1$  y  $G_2$  no son datos anómalos. Los métodos basados en distancias descritos en los apartados anteriores no detectarían los anómalos  $P_1$  y  $P_2$ , algo que sí haría LOF.

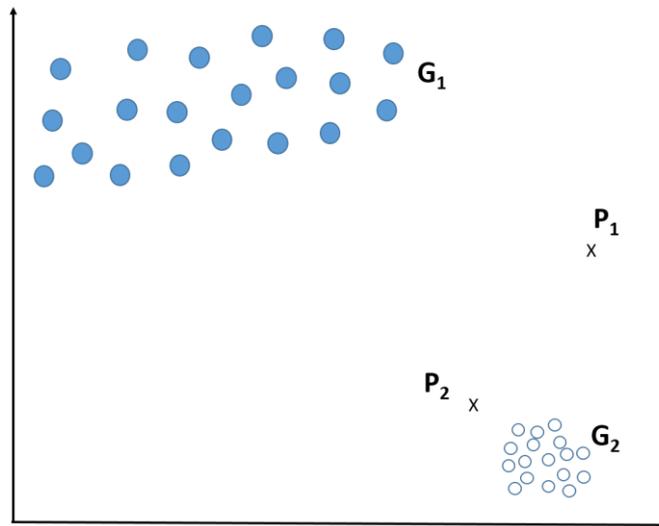


Figura 3-2: Ejemplo de anomalos  $P_1$  y  $P_2$  en un conjunto de datos 2-D

### 3.6.3.2. COF (Connectivity-base Outlier Factor)

El método LOF puede pasar por alto aquellos valores anómalos potenciales cuya densidad de vecindad local es muy cercana a la de sus vecinos. Para abordar este problema, [99] propuso un nuevo esquema basado en la conectividad de factor atípico (COF - Connectivity-base Outlier Factor) que mejora la eficacia del esquema LOF cuando un patrón de datos tiene una densidad de vecindad similar a un valor anómalo.

Para modelar la conectividad de un punto de datos con respecto a un grupo de sus vecinos, se define *SBN-path* (Set-Based Nearest path) y *SBN-trail* (Set-Based Nearest trail) a partir de este punto de datos. COF define la métrica de anomalía de un punto  $p$  con respecto a su  $k$ -vecindario como

$$COF_k(p) = \frac{|N_k(p)| \text{acdist}_{N_k(p)}(p)}{\sum_{o \in N_k(p)} \text{acdist}_{N_k(o)}(o)} \quad \text{Ec. 3-4}$$

Donde  $\text{acdist}_{N_k(p)}(p)$  es la distancia media de encadenamiento desde el punto  $p$  al resto de sus  $k$ NN, que es la suma ponderada del coste del *SBN-trail* a partir de  $p$ .

### 3.6.3.3. Ventajas y desventajas de los métodos basados en densidad

Tal y como se comenta en [79], las principales ventajas de estos métodos son:

1. Los métodos de detección de valores atípicos basados en la densidad son

generalmente más eficaces que los métodos basados en la distancia.

En cuanto las desventajas se tienen:

1. Los métodos basados en la densidad son más complicados y costosos computacionalmente.
2. Para un objeto de datos, tienen que explorar no sólo su densidad local sino también la de sus vecinos.

### **3.6.4. Métodos basados en clustering**

Otros métodos para detectar anomalías en conjunto de datos de baja dimensionalidad son los modelos basados en clustering. En la literatura muchos algoritmos de aprendizaje automático pueden encontrar los valores atípicos como un subproducto de los algoritmos de agrupación donde ya se clasifican determinados puntos como anómalos por no poder asignarlos claramente a un clúster en concreto [79].

Como se explica en [70], el análisis clúster [100] es una técnica popular de aprendizaje que agrupa las instancias de datos similares en clústeres. Se utiliza como una herramienta que por sí sola puede obtener información sobre la distribución de un conjunto de datos, o como un paso previo de procesamiento para otros algoritmos que operan en los clústeres detectados. El clustering es principalmente una técnica no supervisada, aunque también hay referencias de modelos de este tipo que son semi-supervisados [101].

#### **3.6.4.1. Agrupación de clústeres**

Los métodos de agrupación de clústeres realizan dicha agrupación dividiendo el conjunto de datos en un número específico de clústeres. El número de clústeres a obtener, denotado por  $k$ , es especificado por el usuario. Normalmente comienzan con una partición inicial del conjunto de datos y luego optimizan iterativamente la función objetivo hasta que alcanza el óptimo para el conjunto de datos. En el proceso de agrupación, se utiliza el centro de los clústeres (métodos basados en centroides) o el punto que se encuentra más próximo al centro del clúster (métodos basados en  $k$ -medoides) para representar un grupo. Métodos de agrupación de clústeres representativos son PAM (Partitioning Around Medoids), CLARA (Clustering LARge Applications) [102],  $k$ -means [103] y CLARANS (Clustering Large Applications based on RANdomized Search) [104].

#### 3.6.4.2. Agrupación jerárquica

Los métodos de agrupación jerárquica esencialmente construyen una descomposición jerárquica de todo el conjunto de datos. Estos métodos pueden dividirse en dos categorías atendiendo a cómo se opera este dendrograma para generar clústeres: *métodos aglomerativos* y de *división*. Un *método aglomerativo* comienza con cada punto como un clúster distinto para luego unir los dos clústeres más cercanos en cada paso hasta que se cumple un criterio de parada. Un *método de división*, al contrario que un método aglomerativo, comienza con todos los puntos como un solo racimo y lo divide en cada paso subsiguiente hasta que se cumple un criterio de detención. En la práctica los métodos de aglomeración se utilizan más frecuentemente que los de división. Los métodos jerárquicos más representativos son MST clustering (Minimum Spanning Tree clustering) [105], CURE (Clustering Using Representative) [106] y CHAMELEON [107].

#### 3.6.4.3. Clustering basado en densidad

Los algoritmos de agrupación basados en densidad consideran los clústeres como regiones densas de objetos en el espacio de datos y que están separados por regiones de baja densidad. Los humanos normalmente identifican un grupo porque hay una región relativamente más densa en comparación con su vecindario más escaso. Los algoritmos de agrupación basados en densidad más representativos son DBSCAN (Density-Based Spatial Clustering of Applications with Noise) [108] y DENCLUE (Density-Based Clustering with Constrains) [109].

#### 3.6.4.4. Clustering basado en cuadrícula (grid)

Los métodos de agrupación basados en la cuadrícula realizan agrupaciones basadas en una estructura de datos similar a una rejilla con el objetivo de mejorar la eficiencia de la agrupación. Cuantifica el espacio en un número finito de celdas que forman una estructura de cuadrícula en la que se realizan todas las operaciones de agrupamiento. La ventaja principal de este tipo de enfoque es su rápido tiempo de procesamiento, que típicamente sólo depende del número de celdas en el espacio cuantificado, en lugar del número de objetos de datos. Los representantes de este tipo de algoritmos son STING (Statistical Information Grid-based method) [110], WaveCluster [111] y DClust (Dynamical Clustering) [112].

#### 3.6.4.5. Ventajas y desventajas de los métodos basados en clustering

Tal y como se comenta en [79], las principales ventajas de este método son:

1. La detección de valores anómalos mediante un análisis de agrupamiento es bastante intuitiva y coherente con la percepción humana de los valores anómalos.
2. El agrupamiento es un área de investigación bien establecida y hay disponibles abundantes algoritmos de agrupación que los usuarios pueden elegir para realizar el agrupamiento y luego detectar valores anómalos.
3. Las agrupaciones de datos dependen de los datos dependen del orden en que se analicen los datos. En este sentido parecería un método poco robusto.

En cuanto a las desventajas se pueden mencionar:

1. Las salidas de estos modelos de valores atípicos, en el contexto de la agrupación, son esencialmente de naturaleza binaria, sin ninguna indicación cuantitativa de la forma en que cada objeto es periférico. En muchas aplicaciones es deseable que la anomalía de estos valores atípicos pueda ser cuantificada y clasificada.
2. Los algoritmos de agrupamiento están enfocados sólo en agrupar los objetos en el conjunto de datos de modo que se puedan optimizar las funciones de agrupamiento. El objetivo de eliminar los valores anómalos en el conjunto de datos mediante la agrupación solo está pensado para amortiguar su efecto adverso sobre el resultado de la agrupación final.

### 3.7. Métodos de detección de anómalos para datos de alta dimensionalidad

Existen muchas aplicaciones en dominios de alta dimensionalidad en los que los datos pueden contener docenas o incluso cientos de dimensiones. Las técnicas de detección de valores anómalos que se han revisado en las secciones anteriores usan varios conceptos de proximidad para encontrar dichos valores basados en su relación con los otros puntos del conjunto de datos. Sin embargo, en el espacio de alta dimensión, los datos son dispersos y los modelos que utilizan la noción de proximidad no consiguen la mayor parte de su eficacia. Esto se debe a lo que se ha venido a llamar *maldición de la dimensionalidad* (course of dimensionality). Este

concepto fue introducido por Bellman en 1957 y describe el problema de los datos de alta dimensión que tienden a estar equidistantes entre sí a medida que aumenta dicha dimensionalidad. Esto obliga a que la cantidad de datos necesarios, para obtener un resultado estadísticamente sólido y fiable, debe crecer también exponencialmente con la dimensionalidad.

### **3.7.1. Cubo disperso**

Esta técnica para la detección de valores anómalos que observa los valores atípicos observando las distribuciones de densidad de las proyecciones a partir de los datos es descrita en [113] y [114]. Esta nueva definición considera un punto como un valor anómalo si en alguna proyección de dimensiones inferiores se encuentra en una región local de densidad anormalmente baja.

### **3.7.2. Método basado en ejemplos**

Una aproximación utilizando ejemplos anómalos proporcionados por el usuario se utiliza para detectar anómalos en espacios de alta dimensionalidad [115], [116]. Adopta un subespacio de ejemplos del tipo “ejemplos anómalos → subespacios → anómalo” para detectar valores atípicos. Específicamente, los expertos en el dominio proporcionan primero a los sistemas algunos ejemplos iniciales inusuales. El algoritmo detecta los subespacios en los que la mayoría de estos ejemplos anómalos presentan una anomalía mayor. Finalmente, se detectan otros valores anómalos de estos subespacios obtenidos en el paso anterior. Este enfoque divide el espacio de datos en celdas de igual profundidad y emplea el coeficiente de dispersión propuesto en [113] para medir el carácter anómalo de ejemplos en cada subespacio de la red.

### **3.7.3. Detección de anómalos en subespacios**

Un buen ejemplo de solución para este caso aparece en [117] donde se emplea un algoritmo evolutivo para la selección de características. Es decir, encontrar los subconjuntos de dimensión óptima que representan el conjunto de datos original sin perder la información para la tarea de aprendizaje sin supervisión de la detección de valores anómalos, así como la agrupación. Este enfoque es un algoritmo de envoltura en el que los subconjuntos de dimensión se seleccionan de tal manera que se puede optimizar la calidad de los valores anómalos detectados o los clústeres generados. La originalidad de este trabajo es combinar el algoritmo evolutivo con una técnica de visualización de datos, utilizando coordenadas paralelas para presentar los resultados evolutivos de forma

interactiva y permitir a los usuarios participar activamente en la búsqueda de algoritmos evolutivos para lograr una rápida convergencia del algoritmo.

#### **3.7.4. Detección de anomalos en subespacios para datos categóricos**

Se basan en un enfoque de probabilidad para la detección de valores anómalos. Se investigan, para cada registro en el conjunto de datos, las probabilidades para la ocurrencia de diferentes subconjuntos de atributos. Un registro de datos se etiqueta como un valor atípico si la probabilidad de ocurrencia para los valores de algunos de sus subconjuntos de atributos es suficientemente baja [118].

### **3.8. Detección de anomalos en subespacios de alta dimensionalidad**

Todos los algoritmos de detección de valores anómalos que se han discutido hasta ahora, independientemente de que el escenario dimensional sea bajo o alto, invariablemente caen en el marco de la detección de valores anómalos en un espacio de datos determinado, ya sea en un espacio completo o subespacio. Se suelen llamar a estas técnicas como técnicas “espacio  $\rightarrow$  anomalos” [79]. Los valores anómalos suelen ser detectados mediante una primera búsqueda localmente dispersa de subespacios [114], y los llamados anomalos fuerte y débiles son descubiertos por una primera búsqueda de los espacios de anomalía más fuertes [119]. Un nuevo problema de investigación llamado *detección de subespacios anomalos* (outlying subspaces) en datos multidimensionales o de alta dimensión se ha identificado en los últimos años [120]. La tarea principal de la detección de subespacios anomalos es encontrar los subespacios (subconjunto de características) en el que los puntos de interés de los datos muestran una desviación significativa del resto de la población. Este problema se puede formular de la siguiente manera: dado un punto de datos  $u$  objeto, encontrar los subespacios en los que estos datos son considerablemente diferentes, excepcionales o incoherentes respecto a los puntos  $u$  objetos restantes. Estos puntos bajo estudio se llaman puntos de consulta, que suelen ser los datos en los que los usuarios están interesados. Un umbral de distancia  $T$  se utiliza para decidir si un punto de datos se desvía significativamente o no de sus puntos vecinos. Como ejemplo de algoritmos de este tipo se tiene HighDOD (High-Dimension Outlying subspace Detection) [120] y SOF (Subspace Outlying Factor) [121].

### 3.9. Detección de anomalos o eventos en flujos de datos

Tal y como se comenta en [122], en muchas aplicaciones los datos no son estáticos, sino que llegan en forma de flujos de datos. Además de la diferencia algorítmica que hay que aplicar entre el procesamiento de flujos de datos y los datos estáticos, hay otra diferencia significativa. Para conjuntos de datos estáticos, es razonable suponer que los datos fueron generados por un proceso fijo, por ejemplo, los datos son una muestra de una distribución estática. Pero un flujo de datos tiene necesariamente una dimensión temporal, y el proceso subyacente que genera el flujo de datos puede cambiar con el tiempo. La cuantificación y detección de dicho cambio es uno de los desafíos fundamentales en la configuración de los flujos de datos.

El cambio tiene un impacto de largo alcance en cualquier algoritmo de procesamiento de datos. Por ejemplo, al construir modelos de aprendizaje automático para flujos de datos, los datos que llegaron antes de un cambio pueden polarizar los modelos hacia características que ya no se mantienen. Si se procesan consultas sobre flujos de datos, es posible que se desee dar respuestas separadas para cada intervalo de tiempo en el que la distribución de datos subyacente es estable. La mayoría de los trabajos existentes se han concentrado en algoritmos que se adaptan a las distribuciones cambiantes, ya sea descartando datos antiguos o dándoles menos peso.

Siguiendo a [123], en este trabajo se define el cambio en flujos de datos al proceso de transición desde un estado o forma a otro. En un flujo de datos, el cambio se produce cuando el proceso de generación de datos se desplaza desde un modelo de generación de dichos datos a otro. Este desplazamiento suele producirse por un cambio en los parámetros del modelo. Por ejemplo, si los datos observados son generados siguiendo una distribución Gaussiana  $N(\mu, \sigma^2)$  con media  $\mu$  y varianza  $\sigma^2$  desde  $N(0; 1)$  a  $N(0; 2)$ . Los algoritmos para la detección de flujos deberán detectar estos cambios de distribución.

En la Tabla 3-1 puede verse un resumen de los principales métodos de detección de anomalos en flujos de datos.

#### 3.9.1. Requerimientos de un algoritmo para la detección de eventos en flujos de datos

Tal y como describe [124] cualquier algoritmo de proceso de flujo de datos debe cumplir las siguientes características:

1. **Procesar un ejemplo en cada instante de tiempo e inspeccionarlo una sola vez.** La característica principal de un flujo de datos es que los datos entran de uno en uno. Una vez que el dato ha sido tratado se desecha sin la posibilidad de recuperarlo posteriormente. Esta condición puede ser relajada en los casos en los que el flujo de datos es reenviado para que un segundo algoritmo refine el modelo que ha aprendido. No obstante, para que un algoritmo sea lo suficientemente flexible y pueda aplicarse de forma universal a cualquier flujo de datos deberá ser de un solo paso.
2. **Utilizar una cantidad de memoria limitada.** Probablemente la principal motivación para emplear un algoritmo de flujo de datos es que permite el proceso de datos en aquellos casos en los que estos son de un tamaño mayor que la memoria disponible.
3. **Necesidad de tiempo de proceso limitado.** Para que un algoritmo sea escalable para cualquier número de ejemplos, su tiempo de ejecución debe ser lineal. Para que un algoritmo pueda trabajar en *tiempo real* debe tratar los ejemplos tan rápido, o más, que la velocidad de los datos que le llegan. Lo contrario significaría la pérdida de datos. Esta característica puede relajarse en el caso de que se realicen procesamientos diferidos (off-line) o simplemente si el usuario de dicho algoritmo solo quiere obtener resultados en un tiempo razonable.
4. **Estar preparado para realizar detecciones en cualquier momento.** Un algoritmo ideal debe ser capaz de detectar el cambio a partir de los datos observados después de ver un número determinado de ejemplos.

Para el caso particular de un algoritmo secuencial y/o en tiempo real efectivo para detectar cambios se requiere adicionalmente que:

1. El tiempo medio entre que se produzca un cambio y su detección sea mínimo.
2. El número de cambios reales no detectados y falsas alarmas (FA) sea mínimo.

Tabla 3-1: Resumen de los principales métodos de detección de anómalos según [79]

Categoría	Método	Anómalos en subespacios de alta dimensionalidad	Flujo de datos (Data Stream)
Métodos estadísticos de detección	Modelos Gaussianos	x	x
	Modelos de regresión	x	✓
	Histogramas	x	✓
	Funciones Kernel	x	✓
Métodos basados en distancias	$DB(k, \lambda) - Outliers$	x	x
	$DB(pct, d_{min}) - Outliers$	x	x
	Método $K^{th}$ NN	x	x
	Método Sum $K^{th}$ NN	x	x
	Grid-ODF	x	x
Métodos basados en densidad	LOF	x	x
	COF	x	x
	INFLO	x	x
	MDEF	x	x
	Incremental LOF	x	✓
Métodos basados en agrupamientos	PAM/CLARA	x	x
	$k$ -means	x	x
	CLARANS	x	x
	MST Clustering	x	x
	BIRCH	x	✓
	CURE	x	x
	CHAMALEON	x	x
	DBSCAN	x	x
	DENCLUE	x	x
	STING	x	✓
	WaveCluster	x	✓
	DCLUST	x	✓
	STREAM	x	✓
	BIRCH*	x	✓
CluStream	x	✓	
Métodos de detección de anómalos de alta dimensionalidad	Métodos de coeficientes de dispersión	✓	x
	Métodos basados en ejemplos	✓	x
	HighDoD	✓	x
	Métodos SOF	✓	x
	CLIQUE	✓	x
	HPStream	✓	✓

### 3.10. Detección de cambios basado en predictores conformales

A continuación, se describirá una solución basada en predictores conformales y martingalas para la detección de cambios. Se comenzará por la distinción entre escenarios de aprendizaje *On-Line* y *Off-Line*, se seguirá con predicciones inductivas y transductivas, y se describirá qué es un predictor conformal.

Finalmente se definirán los diferentes elementos necesarios para construir un test de intercambiabilidad *On-Line* [125].

### 3.11. Predicciones inductivas y transductivas

Vapnik [126] formuló una distinción entre la inducción y la transducción aplicada al problema de predicción, que se ve representada en la Figura 3-3. En la predicción inductiva, se obtienen reglas o modelos más o menos generales a partir de un conjunto de entrenamiento, que se llamarán ejemplos y que son representativos de la distribución de los datos a predecir. En la *predicción transductiva*, se toma un acceso directo, por lo que se pasa de los ejemplos anteriores a directamente la predicción de un nuevo ejemplo.

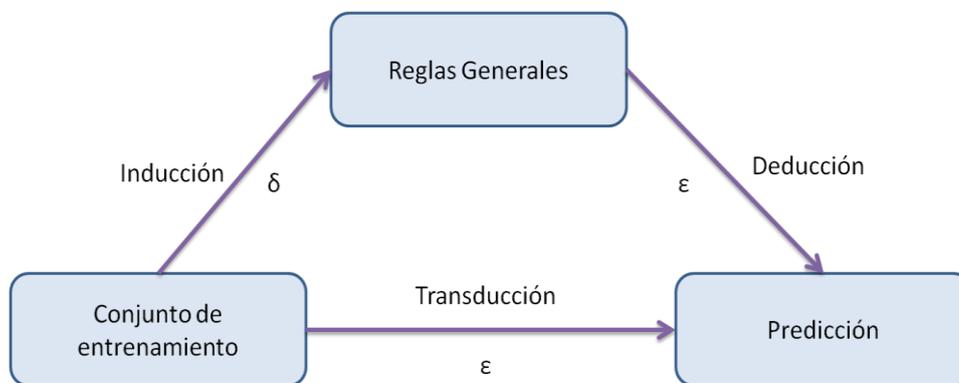


Figura 3-3: Predicción inductiva y transductiva

En el caso de predicciones sencillas, la distinción entre la inducción y la transducción resulta ser menos nítida.

La diferencia entre los escenarios de aprendizaje transductivo e inductivo se puede analizar desde diferentes perspectivas (conceptual, matemática o computacional):

- **Punto de vista conceptual:**
  - *Métodos inductivos:* la *inferencia inductiva* tiene como objetivo la estimación de una función (o modelo) para todos los valores posibles del *espacio de entradas*.
  - *Métodos transductivos:* la *transducción* es más simple que la inducción, en la *transducción* la inferencia se implementa de forma que se estiman los valores de la función (o modelo) solamente para un conjunto discreto de puntos, lo que constituye un problema relativamente más simple [127].

- **Punto de vista matemático:**
  - *Métodos inductivos:* Cualquier método *inductivo* crea una regla de predicción que puede ser aplicada a diversos objetos nuevos y el objetivo es que al emplear la regla se tenga una alta probabilidad de realizar predicciones con elevada precisión. Implica el control de dos parámetros, la precisión deseada para la regla ( $\epsilon$ ) y la probabilidad de alcanzar dicha precisión ( $\delta$ ).
  - *Métodos transductivos:* por tener un objetivo más modesto, los métodos *transductivos* implican el control de un único parámetro, la probabilidad del error a ser tolerado ( $\epsilon$ ) al aplicar el método [128].
  
- **Punto de vista computacional:**
  - *Métodos inductivos:* la mayor parte del coste computacional está asociado a la creación de la regla de predicción, paso designado como *entrenamiento*, mientras que la aplicación de la regla sobre nuevos objetos, paso designado como *test*, es relativamente simple y tiene un coste computacional despreciable. El hecho de que la regla de predicción se cree una única vez, siendo después empleada reiteradas veces en la predicción de objetos nuevos, reduce la exigencia computacional de esta clase de métodos.
  - *Métodos transductivos:* en la práctica este tipo de métodos están asociados a un mayor coste. No existe una separación clara entre las fases de entrenamiento y test, siendo la regla de predicción creada de forma implícita en el acto de predicción. De este modo, la exigencia computacional es más alta por ser necesario crear una regla implícita al predecir cada objeto nuevo, en el caso en que los objetos se predigan de forma secuencial, uno a uno [128], o formular la inferencia como un problema combinatorio, en el caso en que se realiza la predicción simultánea para un conjunto de objetos nuevos [127].

### 3.12. Aprendizaje On-Line y Off-Line

La teoría de los predictores conformales fue desarrollada en un escenario de aprendizaje *On-Line* [128]. En este escenario, se asume que los ejemplos son presentados uno a uno. Primero, el predictor observa el objeto  $x_1$  y predice su etiqueta  $\hat{y}_1$ . A continuación, recibe la etiqueta verdadera  $y_1$ , proporcionada por

un *maestro*, seguidamente observa el segundo objeto  $x_2$ , y predice la etiqueta correspondiente. Este proceso sigue hasta que se realiza la predicción de las etiquetas de todos los objetos.

En el  $n$ -ésimo paso, el predictor tendrá observado los ejemplos anteriores  $(x_1, y_1), \dots, (x_{n-1}, y_{n-1})$  y observará el nuevo objeto  $x_n$  para realizar la predicción de su etiqueta. Al final de cada paso existe nueva información disponible y así la calidad de las predicciones va mejorando a medida que se incrementa la cantidad de pasos.

El escenario de aprendizaje *On-Line* implica que la etiqueta verdadera de un objeto sea proporcionada inmediatamente después de la predicción. Esto hace que su implementación práctica sea cuestionable. En la mayoría de las aplicaciones reales cualquier forma de realimentación es costosa o simplemente no está disponible. En [128] se consideran relajamientos al escenario *On-Line* que permitan soslayar el problema anteriormente descrito.

Los predictores conformales pueden ser utilizados en un escenario de aprendizaje *Off-Line*, también conocido como aprendizaje en lotes (batch learning). Se describe como, dado un conjunto de entrenamiento  $(x_1, y_1), \dots, (x_n, y_n)$ , el objetivo es predecir las etiquetas de los objetos dados en el conjunto de test  $x_{n+1}, \dots, x_{n+k}$ . No existe realimentación de las etiquetas verdaderas después de cada predicción y, por tanto, no existe nueva información para reentrenar al predictor.

En este escenario de aprendizaje, la propiedad de validez de los predictores conformales, que se verá en la sección 3.13, sigue siendo válida. Desde el punto de vista teórico la garantía de validez en este escenario disminuye con respecto al escenario *On-Line* [128], pero existe una fuerte evidencia empírica de que los predictores conformales son válidos en el mismo [129].

### 3.13. Predictores conformales

En esta sección se describe el concepto de predictor conformal que se utilizarán más adelante en nuestra descripción del modelo de detección de cambios. Lo descrito en esta sección se basa en la descripción que se hace de los mismos en [130].

#### 3.13.1. Introducción

Los predictores conformales son un método de predicción que proporciona una

evaluación de su precisión y fiabilidad y que pueden ser utilizados con cualquier método de predicción para clasificación, clustering y regresión incluyendo, entre otros, máquinas de vector soporte (SVM – Support Vector Machine), árboles de decisión, redes neuronales y modelos de regresión.

Para estimar la confianza en las predicciones con métodos de aprendizaje automático, uno de los métodos más típicos es el conocido como método del estimador *Holdout*. Con el propósito de calcular este estimador, los ejemplos disponibles son divididos en dos grupos: un conjunto de entrenamiento y un conjunto de test. El conjunto de entrenamiento es utilizado para encontrar una regla de predicción (proceso de aprendizaje) y luego esta regla de predicción es aplicada al conjunto de test. La ratio de observaciones correctas en el conjunto de test es utilizada como una medida de confianza de las reglas de predicción cuando es aplicada a los nuevos ejemplos.

Los predictores conformales tienen varias ventajas sobre los estimadores *Holdout*:

1. Los predictores conformales no hacen una separación rígida entre aprendizaje y estimación. Todos los objetos son tratados simultáneamente y, por tanto, aprendizaje y predicción se combinan.
2. Como consecuencia de esta mezcla, los predictores conformales aprenden y predicen al mismo tiempo, mejorando continuamente su rendimiento tal y como va realizando cada nueva predicción y buscando cómo ajustarse. De esta forma, no es necesario realizar reentrenamientos.
3. Las predicciones son más fiables y precisas porque una nueva medida de confianza es obtenida en cada clasificación, sin confiarla a valores obtenidos con un conjunto fijo de ejemplos (conjunto de entrenamiento).
4. La confianza en la etiqueta predicha en cada nueva clasificación se toma de los objetos previos y todas las etiquetas posibles.
5. Un predictor conformal puede detectar ambigüedades en sus tareas de clasificación, por ejemplo, cuando una única clase no puede ser asignada a un nuevo ejemplo. En algunas circunstancias, detectar la ambigüedad puede ser más importante que producir una mala estimación.

### 3.13.2. Medida de no conformidad

Para determinar el nivel preciso de confianza en las predicciones, los predictores conformales utilizan la experiencia obtenida de los ejemplos tratados con anterioridad. Para cada nuevo ejemplo a clasificar, es necesario medir cuán diferentes es el ejemplo actual de los anteriores. Para ello es necesario definir una medida de no conformidad y se debe determinar una puntuación de no

conformidad para estimar cómo de diferente es un nuevo ejemplo respecto a una *bolsa* con los antiguos ejemplos [131].

Se define una bolsa de tamaño  $n \in \mathbb{N}$  como una colección de  $n$  elementos, alguno de los cuales pueden estar repetidos. Es como un conjunto en la medida en la que sus elementos no están ordenados y como una lista en la medida en la que un elemento puede ocurrir más de una vez. Se escribirá  $\{ a_1 \cdots a_n \}$  para la lista  $a_1 \cdots a_n$  eliminando la información sobre el orden.

Dada una medida de no conformidad  $A$  y una bolsa  $\{ z_1 \cdots z_n \}$  es posible calcular el valor de no conformidad

$$\alpha_1 = A(\{ z_i, \dots, z_{i-1}, z_{i+1}, \dots, z_n, z_i \}) \quad \text{Ec. 3-5}$$

para cada ejemplo  $z_i$  en la bolsa.

Por regla general, cada ejemplo es asignado a una medida de no conformidad  $\alpha_i$  tal y como se muestra en la Ec. 3-5 mediante la aplicación de algún método predictivo. En general, existen varios tipos de medida de no conformidad, también llamadas *extrañezas*, relacionadas con métodos predictivos de clasificación, clustering y regresión [28]. En la siguiente sección se detallan algunos ejemplos de estos métodos.

### 3.13.3. Medidas de extrañeza

#### 3.13.3.1. k-NN: k vecinos más cercanos

Dada una secuencia de distancias entre los miembros de un conjunto de entrenamiento determinado, que cuantifica en qué medida es probable la etiqueta de un ejemplo; se define la medida de no conformidad del ejemplo  $i$  con la etiqueta  $y$  en relación con el resto de los ejemplos de entrenamiento como:

$$s_i = \frac{\sum_{j=1}^k d_{ij}^y}{\sum_{j=1}^k d_{ij}^{-y}} \quad \text{Ec. 3-6}$$

Donde  $d_{ij}^y$  es la  $j$ -ésima distancia más corta en la secuencia de distancias ordenada ascendentemente del ejemplo  $i$  a los otros ejemplos con la misma etiqueta de clase  $y$ , y  $d_{ij}^{-y}$  es la  $j$ -ésima distancia más corta de la secuencia ordenada de distancias del ejemplo  $i$  desde los ejemplos con etiqueta de clase diferente de  $y$ . La *extrañeza* en este caso será el resultante de la ratio de la suma

de las  $k$  distancias más cercanas de la misma clase, a la suma de las  $k$  distancias más cercanas de las otras clases. La *extrañeza* de un ejemplo con etiqueta  $y$ , será mayor cuando la distancia desde los ejemplos de la misma clase sea más amplia y cuando la distancia a las otras clases es menor.

### 3.13.3.2. SVM: Máquinas de vector soporte

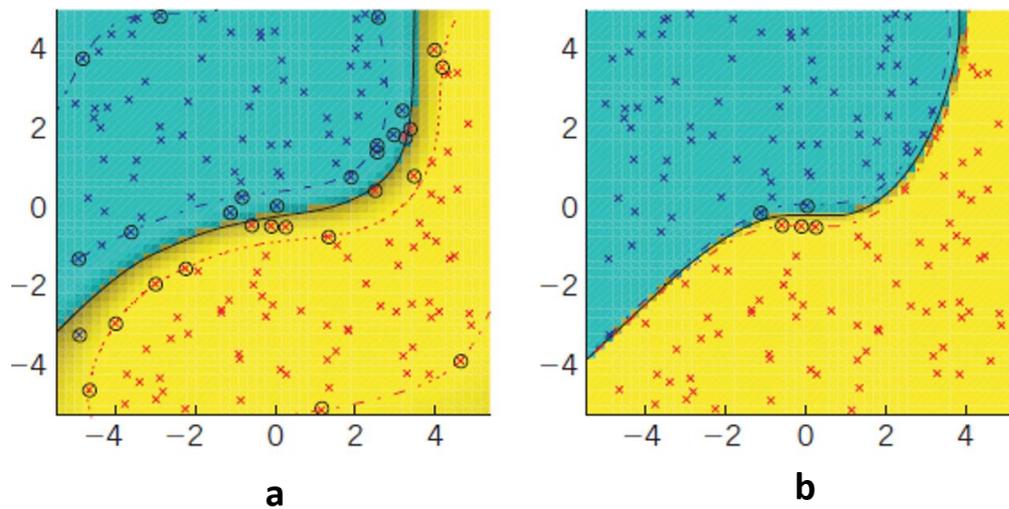
Dado el conjunto de entrenamiento  $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$  donde  $y_i \in \{-1, 1\}$ , SVM [132] busca el hiperplano que produce el margen máximo.

Cuando un nuevo ejemplo  $\mathbf{x}_{n+1}$  es incluido con una etiqueta  $y_{n+1}$  en el conjunto de entrenamiento, que emplea los multiplicadores de Lagrange  $\lambda_1, \lambda_2, \dots, \lambda_n, \lambda_{n+1}$  asociados con los ejemplos en el conjunto de entrenamiento y,  $(\mathbf{x}_{n+1}, y_{n+1})$  como la medida de *extrañeza* cuando utilizamos el SVM. Los multiplicadores de Lagrange  $\lambda_i, i = 1, \dots, n+1$  se hallan mediante la maximización de la formulación dual de un SVM con margen blando (*soft-margin SVM*):

$$Q(\lambda) = -\frac{1}{2} \sum_{i=1}^{n+1} \sum_{j=1}^{n+1} \lambda_i \lambda_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) + \sum_{i=1}^{n+1} \lambda_i, \quad \text{Ec. 3-7}$$

Sujeto a las restricciones  $\sum_{i=1}^{n+1} \lambda_i y_i = 0$  y  $0 \leq \lambda_i \leq C, i = 1, \dots, n+1$ , donde  $K(\mathbf{x}_i, \mathbf{x}_j)$  es una función de kernel y  $C$  una constante estrictamente positiva.

Los SVM de margen blando son más robustos porque son capaces de generalizar aun cuando los datos contengan ruido. En la Figura 3-4 se ve un ejemplo gráfico de SVM con dos tipos diferentes de kernels.



**Figura 3-4:** (a) curva de decisión generada por el clasificador mediante la función de kernel de base radial ( $\sigma = 2$ ) y  $C = 2$ . (b) curva de decisión generada por el clasificador mediante la función de kernel polinomial ( $\beta = 1, n = 3$ ) y  $C = 2$ . Los vectores soporte están rodeados con un círculo. Las líneas de punto indican el margen [133]

La idea principal de las SVM con margen blando es la introducción de variables de holgura ( $\xi$ ), que permiten que las restricciones no se cumplan de manera estricta. El vector de variables de holgura tiene la misma dimensión que el conjunto de datos. Cada una de las componentes indica la máxima diferencia entre 1 (el teórico margen funcional mínimo) y el margen real de cada ejemplo. El mínimo valor que puede tener una variable de holgura es 0. Como contrapartida, se introduce en la función a optimizar un término de regularización que depende de las mismas. Este término de regularización incluye una constante  $C$ , que determina la holgura del margen blando. Valores grandes de  $C$  obligan a tener pocas variables de holgura diferentes de 0 (o con valores grandes) en la solución final. Esta constante habrá que fijarla a priori y es, por tanto, un parámetro del aprendizaje [134].

La relación entre *extrañeza* y multiplicadores de Lagrange puede explicarse de la siguiente forma: Los ejemplos fuera del margen y en el lado correcto del hiperplano no tiene ningún multiplicador de Lagrange. Para los ejemplos en el margen, los valores de los multiplicadores de Lagrange están entre 0 y  $C$ . Todos los ejemplos dentro del margen tienen multiplicadores de Lagrange con valor  $C$ . Los ejemplos con mayor medida de no conformidad son aquellos dentro del margen y en el lado erróneo del hiperplano, mientras que los que están correctamente etiquetados fuera del margen son los que tienen una medida de no conformidad menor.

### 3.13.3.3. Modelos de clúster

Dado el conjunto de datos sin etiquetar  $T = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ , se define la medida de no conformidad de un ejemplo  $\mathbf{x}_i$  en relación con un modelo de *clúster* como:

$$s(T, \mathbf{x}_i) = \|\mathbf{x}_i - c\| \quad \text{Ec. 3-8}$$

Donde  $c$  es el centroide del *clúster* y  $\|\cdot\|$  es una distancia métrica.

### 3.13.3.4. Modelos de regresión

Dado un conjunto de entrenamiento  $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$  donde  $y_i \in \mathbb{R}$ , se define la medida de no conformidad de un ejemplo  $(\mathbf{x}_i, y_i)$  con respecto a un modelo de regresión como:

$$s(T, (\mathbf{x}_i, y_i)) = \frac{|y_i - f(\mathbf{x}_i)|}{e^{g(\mathbf{x}_i)}} \quad \text{Ec. 3-9}$$

Donde  $f$  es la función de regresión y  $g$  es la estimación de la función de error para  $f$  en  $\mathbf{x}_i$ . En nuestro caso, la función de estimación  $g$  está basada en un modelo de regresión de los valores  $\ln(|y_i - f(\mathbf{x}_i)|)$  para  $\mathbf{x}_i$ , donde  $i = 1, \dots, n$ .

### 3.13.4. Cálculo On-Line de p-valores

Utilizando las medidas de no conformidad  $\alpha_i$  obtenidas con algunos de los métodos descritos en la sección 3.13.2 para todos los ejemplos observados, el p-valor  $p_n$  que corresponde al ejemplo  $z_n$  se obtiene calculando:

$$p_n = \frac{\#\{i : \alpha_i > \alpha_n\} + \theta_n \#\{n : \alpha_n = \alpha_n\}}{n} \quad \text{Ec. 3-10}$$

Donde  $\theta_i$  es seleccionada de forma aleatoria dentro del intervalo  $[0, 1]$  para cada valor de  $i$ . El símbolo  $\#$  corresponde a la cardinalidad de un conjunto.

Un resultado estándar de la teoría de los predictores conformales es el teorema que se define a continuación [128]:

**Teorema 3–1** Sea  $N \in \mathbb{N}$  y los ejemplos  $z_n \in \mathcal{Z}, n = 1, \dots, N$ , son generados con una distribución de probabilidad  $P$  sobre  $\mathcal{Z}^N$  de acuerdo con una compresión  $N$ -modelo On-Line. Cualquier transductor conformal suavizado en dicho modelo es exactamente válido (producirá p-valores independientes  $p_n, n = 1, \dots, N$ , distribuidos uniformemente en  $[0, 1]$ ).

El siguiente algoritmo describe un proceso de cálculo *On-Line* de los  $p$ -valores [135]:

---

**Algoritmo 3.1** Generación de  $p$ -valores *On-Line*

---

**Entrada:**  $(z_1, z_2, \dots)$  datos a comprobar.

**Salida:**  $(p_1, p_2, \dots)$  secuencia de  $p$ -valores.

1: **para**  $i = 1, 2, \dots$  **hacer**

2:     observar un nuevo ejemplo  $z_i$

3:     **para**  $j = 1$  hasta  $i$  **hacer**

4:          $\alpha_j = A(\int z_1, \dots, z_i \int, z_j),$

5:     **fin para**

6:      $p_i = \frac{\#\{j: \alpha_j > \alpha_i\} + \theta_n \#\{j: \alpha_j = \alpha_i\}}{i}$

7: **fin para**

---

La propiedad de que los ejemplos generados por una distribución intercambiable generan  $p$ -valores independientes y uniformemente distribuidos nos permite comprobar la intercambiabilidad mediante el cálculo de martingalas como funciones de los  $p$ -valores.

### 3.14. Test de Intercambiabilidad On-Line

Siguiendo [125], se van a definir los diferentes elementos necesarios para construir un test de intercambiabilidad *On-Line*.

#### 3.14.1. Conceptos de aleatoriedad e intercambiabilidad

Sean los elementos  $z_1, z_2, \dots$ , que se denominarán *ejemplos*, de una medida del espacio  $\mathbf{Z}$ . La hipótesis de *aleatoriedad* es aquella en la que cada  $z_n$ ,  $n = 1, 2, \dots$ , es generada de acuerdo con una distribución de probabilidad  $P$  en  $\mathbf{Z}$ , y los ejemplos son independientes unos de otros (de modo que la secuencia  $z_1, z_2, \dots$  es generada por la distribución de potencia  $P^\infty$ ). Una hipótesis muy parecida es la de *intercambiabilidad* que es aquella en la que los ejemplos  $z_1, z_2, \dots$  son generados de acuerdo a una probabilidad de distribución *intercambiable*  $Q$  en  $\mathbf{Z}^\infty$ , por ejemplo, si  $Q$  está formado por la permutación de ejemplos  $z_{\pi(1)}, \dots, z_{\pi(n)}$ , que están distribuidos como los ejemplos originales  $z_1, z_2, \dots$  para cualquier  $n$  y  $\pi$  de  $\{1, \dots, n\}$ . Es inmediato que *a priori* la hipótesis de intercambiabilidad es tan o más débil que la hipótesis de aleatoriedad, puesto que todas las distribuciones de potencia son intercambiables.

### 3.14.2. Martingalas

Para evaluar la hipótesis de aleatoriedad/intercambiabilidad *On-Line*: después de observar cada uno de los ejemplos  $z_n$  el método de evaluación debe generar un número  $M_n$  que refleje la fortaleza de la evidencia hallada frente a la hipótesis. La forma más natural de hacerlo es mediante el uso de una Martingala no negativa que comience con el valor 1. Supóngase en primer lugar que se desea evaluar simplemente la hipótesis de que  $z_1, z_2, \dots$  son generados desde una probabilidad de distribución  $Q$  en  $\mathbf{Z}^\infty$ . Se dirá que una secuencia de variables aleatorias  $M_0, M_1, \dots, \infty$  es una  $Q$ -*supermartingala* si, para todo  $n = 0, 1, \dots, \infty$ ,  $M_n$  es una función medible de  $z_1, \dots, z_n$  (en particular,  $M_0$  es una constante) y

$$M_n \geq \mathbb{E}^Q(M_{n+1} \mid M_1, \dots, M_n) \quad \text{Ec. 3-11}$$

Si  $M_0 = 1$  y  $\inf_n M_n \geq 0$ ,  $M_n$  puede ser estimado como el capital de un jugador que comienza en 1, y que nunca llega a la bancarrota, al comienzo de cada mano  $n$  apuesta a  $z_n$ . Si tal supermartingala  $M$  nunca toma un valor grande, nuestra creencia en  $Q$  es indeterminada; esta intuición es formalizada por la desigualdad de Doob, la cual implica que

$$Q\{\exists n : M_n \geq C\} \leq \frac{1}{C}, \quad \forall C \geq 1 \quad \text{Ec. 3-12}$$

donde  $C$  es una constante positiva.

### 3.14.3. Supermartingalas aleatorias e intercambiables

Cuando se prueba una *hipótesis compuesta*  $\mathcal{P}$  (por ejemplo una familia de distribuciones de probabilidad), se utilizará una  $\mathcal{P}$ -*supermartingala*. Por ejemplo, secuencias de variables aleatorias  $M_0, M_1, \dots$ , las cuales son  $Q$ -*supermartingalas* para todas  $Q \in \mathcal{P}$ . Si  $\mathcal{P}$  es el conjunto de todas las distribuciones de potencia  $P^\infty$ ,  $\mathcal{P}$  oscila sobre la distribución de probabilidad en  $\mathbf{Z}$ , se llamará a  $\mathcal{P}$ -*supermartingalas*, *supermartingalas aleatorias*. El interés se centra en una amplia familia  $\mathcal{P}$  formada por todas las distribuciones de probabilidad intercambiable  $Q$  en  $\mathbf{Z}^\infty$ ; en este caso se utiliza el término *supermartingala intercambiable* para  $\mathcal{P}$ -*supermartingala*.

El teorema de Finetti y el hecho de que los espacios de Borel son cerrados bajo productos contables [128], implica que cada distribución intercambiable  $Q$  en  $\mathbf{Z}^\infty$  es una mezcla de distribuciones de potencia  $P^\infty$  que proporciona  $\mathbf{Z}$  como Borel.

Esto muestra que la noción de supermartingalas aleatorias e intercambiables no negativas coincide en el caso Borel. Pero incluso sin la presunción de que  $\mathbf{Z}$  sea Borel, todas las supermartingalas aleatorias son supermartingalas intercambiables.

### 3.14.4. Martingalas intercambiables aleatorias

Las martingalas intercambiables aleatorias son una secuencia de funciones medibles  $M_n(z_1, \theta_1, \dots, z_n, \theta_n)$  (A cada ejemplo  $z_n$  se le añade un número aleatorio  $\theta_n \in [0, 1]$ ) de modo que, para cualquier distribución de probabilidad intercambiable  $Q$  en  $\mathbf{Z}^\infty$ ,

$$M_n = \mathbb{E}^{Q \times U^\infty}(M_{n+1} | M_1, \dots, M_n), \quad \text{Ec. 3-13}$$

donde  $U$  es una distribución uniforme en  $[0, 1]$ .

### 3.14.5. Martingalas basadas en p-valores

Dada una secuencia de  $p$ -valores se analiza la forma de calcular una función de dichos  $p$ -valores utilizando para ello una martingala.

Sea  $f_i: [0, 1]_i \rightarrow [0, \infty)$ , para cada  $i \in \{1, 2, \dots\}$ . Sea  $(p_1, p_2, \dots)$  la secuencia de  $p$ -valores generada por el algoritmo 3.1. Se consideran las martingalas  $S_n$  de la forma:

$$S_n = \prod_{i=1}^n f_i(p_i), n = 1, 2, \dots \quad \text{Ec. 3-14}$$

donde a  $f_i(p)$  se la denomina función de apuesta y se la denota mediante  $f_i(p_1, \dots, p_{i-1}, p)$  [135].

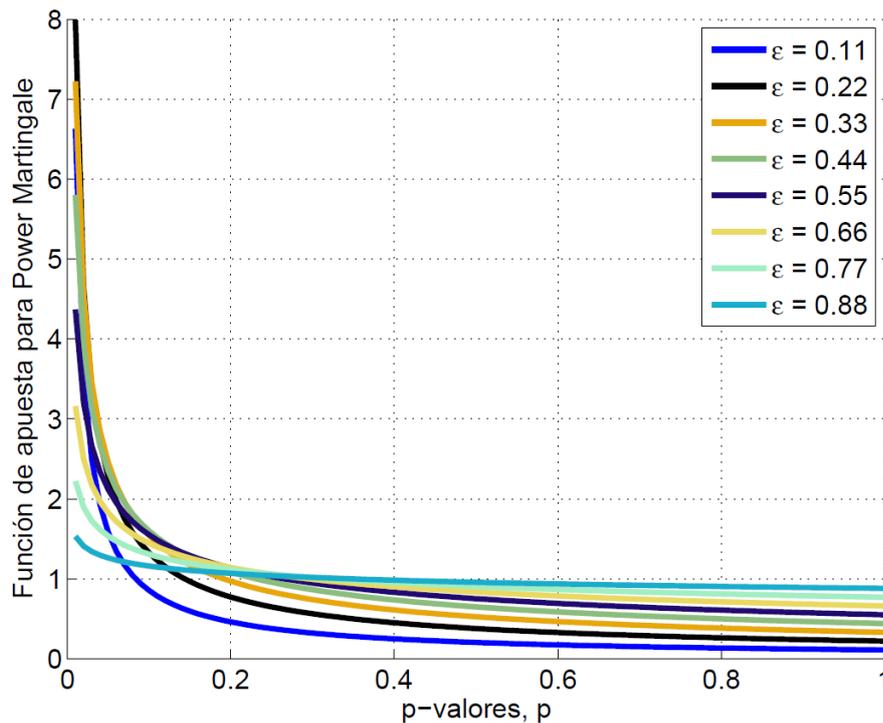
Para asegurarse que Ec. 3-14 es en realidad una martingala, se necesita la siguiente restricción en la función de apuesta  $f_i$ .

$$\int_0^1 f_i(p) dp = 1, \quad n = 1, 2, \dots \quad \text{Ec. 3-15}$$

por tanto, se puede ver que:

$$\begin{aligned}
 E(S_{n+1}|S_0, \dots, S_n) &= \int_0^1 \prod_{i=1}^n f_i(p) f_{n+1}(p) dp \\
 &= \prod_{i=1}^n f_i(p) \int_0^1 f_{n+1}(p) dp \\
 &= \prod_{i=1}^n f_i(p) = S_n
 \end{aligned}
 \tag{Ec. 3-16}$$

Utilizando la Ec. 3-16 se puede actualizar la martingala de forma *On-Line*. Para ello se calcula el  $p$ -valor  $p_i$  para un nuevo ejemplo mediante el algoritmo 3.1, llegando a ser el valor actualizado de la martingala  $S_i = S_{i-1} \cdot f_i(p_i)$ . Con el fin de definir las martingalas completamente es necesario definir la función de apuesta  $f_i$ . A continuación, se definen varios tipos de martingalas a partir de la definición de la función de apuesta  $f_i$ .



**Figura 3-5:** Valores de función de apuesta que se utilizan para calcular Randomized Power y Simple Mixture Martingale

Como se puede ver en la Figura 3-5 las martingalas construidas de esta forma serán crecientes si se analiza una secuencia suficiente de ejemplos cuyos  $p$ -valores tengan valores pequeños.

### 3.14.5.1. Randomized Power Martingale

Tal y como se propone en [128] y considerando el teorema 3.1, los  $p$ -valores se pueden utilizar para construir supermartingalas intercambiables y martingalas intercambiables aleatorias. Por tanto, se tendría que la *función de apuesta* tendría la siguiente forma [135]:

$$\forall i : f_i(p) = \varepsilon p_i^{\varepsilon-1} \quad \text{Ec. 3-17}$$

donde  $\varepsilon \in [0, 1]$ . Varias martingalas pueden ser construidas a partir de esta *función de apuesta*. Entre ellas se tiene que:

$$M_n^\varepsilon = \prod_{i=1}^n \varepsilon p_i^{\varepsilon-1} = \varepsilon^n \left( \prod_{i=1}^n p_i \right)^{\varepsilon-1} \quad \text{Ec. 3-18}$$

donde el valor inicial de esta martingala será 1 y se le denominará *randomized power martingale*. Donde  $p_i$  son los  $p$ -valores emitidos por un transductor conformal suavizado, y formarán una martingala de intercambiabilidad aleatoria no negativa con un valor inicial 1; esta familia de martingalas, indexada por  $\varepsilon \in [0, 1]$ , se llamarán *power martingales* (nótese que  $M_n^{(0)}$  es diferente de las otras martingalas de potencia en esa  $M_0^{(0)} \neq 1$ ) [128].

### 3.14.5.2. Simple Mixture Martingale

A partir de la randomized power martingale y con el fin de eliminar la dependencia de  $\varepsilon$ , se puede utilizar la siguiente martingala intercambiabile aleatoria:

$$M_n = \int_0^1 M_n^\varepsilon d\varepsilon \quad \text{Ec. 3-19}$$

a la Ec. 3-19 se denominará *Simple mixture martingale*.

Si  $p_1, p_2$  son producidas por un transductor conformal determinista, las variables aleatorias de Ec. 3-18 formarán una supermartingala de intercambiabilidad no negativa con valor inicial 1 (a menos que  $\varepsilon = 0$ ), y esta familia de supermartingalas se denomina *Power supermartingales*. La *Simple mixture martingale* (Ec. 3-19) será entonces una supermartingala intercambiabile [128].

### 3.14.5.3. Plug-In Martingale

#### ESTIMACION KERNEL DE LA FUNCIÓN DE DENSIDAD DE PROBABILIDAD

Existen varias referencias para definir estimadores de la densidad por kernel. Se seguirá la descripción que se da en [136], y que también es conocida como **ventana de Parzen**:

- **Estimador de Kernel Univariable**

En este caso el estimador kernel viene dado por:

$$f_{Ker}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) \quad \text{Ec. 3-20}$$

Donde  $K(t)$  es el **kernel**,  $n$  es el número de ejemplos y  $h$  el ancho de ventana. El kernel debe satisfacer la condición  $\int K(t) dt = 1$  para asegurar que la estimación en la Ec. 3-20 es un buen estimador de la densidad. Se define  $K_h(t) = K\left(\frac{t}{h}\right)/h$ , entonces se puede también escribir el estimador kernel de la siguiente forma:

$$f_{Ker}(x) = \frac{1}{n} \sum_i^n 1K_h(x - X_i) \quad \text{Ec. 3-21}$$

Habitualmente, el kernel es una función de densidad de probabilidad que suele utilizar la densidad normal estándar. No obstante, se verá que se pueden utilizar otros tipos de kernels que pueden ser más adecuados para determinados fines.

A continuación, se describe un procedimiento para generar el kernel:

1. Elegir un kernel, un parámetro de suavizado  $h$  y el dominio (conjunto de valores  $x$ ) sobre los que evaluar  $f(x)$ .
2. Para cada  $X_i$ , evaluar el siguiente kernel para todo el dominio:

$$K_i = K\left(\frac{x - X_i}{h}\right) \quad i = 1, \dots, n \quad \text{Ec. 3-22}$$

3. El resultado de esta fórmula será un conjunto de  $n$  curvas, una para cada dato de  $X_i$ .

4. Peso de cada curva para  $1/h$ .
5. Para cada  $x$ , tomar la media de las curvas ponderadas.

El parámetro  $h$  determina el volumen de suavizado que se tiene en el estimador  $f_{ker}(x)$ . Un valor pequeño de  $h$  genera una curva rugosa, mientras que un valor grande de  $h$  genera una curva suavizada. Cuando el ancho de la ventana es pequeño, los resultados del estimador son poco precisos principalmente por la incorporación de ruido. Para valores grandes de  $h$  se obtienen estimadores suavizados que pueden obviar variaciones importantes e interesantes de la estimación. Dado que diferentes valores de  $h$  generan diferentes tipos de clasificadores, es necesario examinar diferentes tipos de estimaciones del kernel de densidad para diferentes tipos de anchos de ventana, y de esta forma decidir cuál es el mejor.

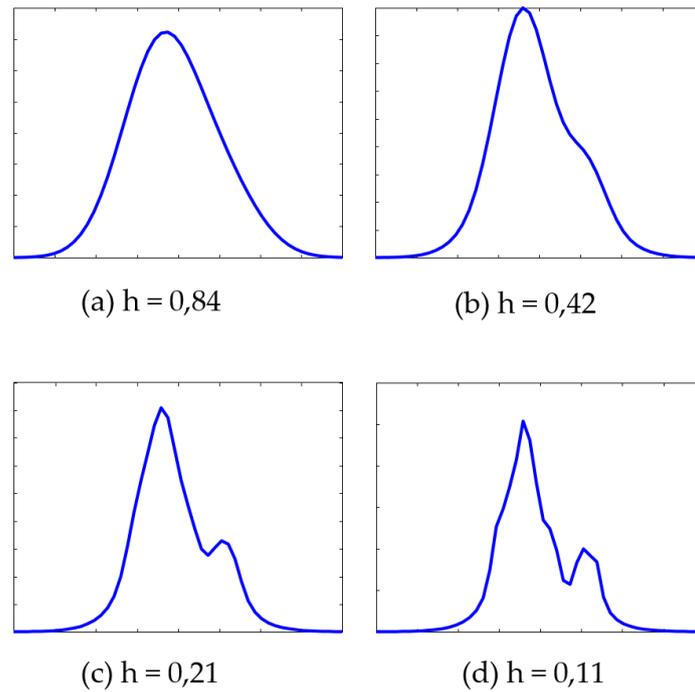
A continuación, se verá la forma de determinar los valores óptimos del parámetro  $h$ . Bajo ciertas condiciones, se sabe que el AMISE (Asymtotic Mean Integrated Squared Error) para un estimador kernel de densidad univariable es:

$$AMISE_{ker}(h) = \frac{R(K)}{nh} + \frac{1}{4} \sigma_k^4 h^4 R(f'') \quad \text{Ec. 3-23}$$

donde el kernel  $K$  es una función de densidad de probabilidad continua con  $\mu_k = 0$  y  $0 < \sigma_k^2 < \infty$ . El ancho de ventana que minimiza la Ec. 3-23 viene dada por

$$h_{ker}^* = \left( \frac{R(K)}{n\sigma_k^4 R(f'')} \right) \quad \text{Ec. 3-24}$$

para el caso de un kernel que es igual a la densidad normal se tiene que  $R(f'') = 3/(8\sqrt{\pi}\sigma^5)$



**Figura 3-6:** Cuatro estimaciones del kernel de densidad utilizando  $n = 100$  y variables generadas aleatoriamente siguiendo distribución normal. Obsérvese que cuanto menor es el valor de  $h$ , la estimación es menos precisa

- **Normal Reference Rule - Kernels**

También conocida como regla del *Pulgar de Silverman*.

$$h_{Ker}^* = \left(\frac{4}{3}\right)^{1/5} \sigma n^{-1/5} \approx 1,06\sigma n^{-1/5} \quad \text{Ec. 3-25}$$

Se puede utilizar alguna estimación idónea para  $\sigma$ , de modo que la desviación estándar tenga la forma  $\sigma = IQR/1,348$ . Con esto se tendría un ancho de ventana de

$$h_{Ker}^* = 0,786 \times IQR \times n^{-1/5} \quad \text{Ec. 3-26}$$

La selección del tipo de kernel para el estimador es otro problema que se debe abordar. En la Tabla 3-2 se pueden ver ejemplos de tipos de kernels.

Tabla 3-2: Ejemplos de Kernels para la estimación de la densidad

Nombre del Kernel	Ecuación	Dominio
Triángulo	$K(t) = (1 -  t )$	$-1 \leq t \leq 1$
Epanechnikov	$K(t) = \frac{3}{4}(1 - t^2)$	$-1 \leq t \leq 1$
Cuártico o Biweight de Tukey	$K(t) = \frac{15}{16}(1 - t^2)^3$	$-1 \leq t \leq 1$
Triweight	$K(t) = \frac{35}{32}(1 - t^2)^3$	$-1 \leq t \leq 1$
Normal o Gaussiano	$K(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}}$	$-\infty < t < \infty$
Coseno	$K(t) = \frac{\pi}{4} \cos\left(\frac{\pi}{2}t\right)$	$-1 \leq t \leq 1$
$K_2$ de Silverman	$K(t) = \frac{3}{\pi}(1 - t^2)^2$	$-1 \leq t \leq 1$

Es conocido que la elección de un kernel para el cálculo de la función de densidad es menos importante que la selección adecuada del parámetro  $h$ . Esto es así porque el efecto que puede producir la selección de un kernel queda suavizado por la media del proceso de cálculo. Dicha elección se centrará, por tanto, en la eficiencia de los diferentes kernels que tiene que ver sobre todo con el coste computacional y la cantidad de diferenciabilidad requerida en la estimación. El más eficiente es el kernel de Epanechnikov [137].

$$f(n) = \begin{cases} \frac{3}{4}(1 - t^2) & \text{si } -1 \leq t \leq 1 \\ 0 & \text{si cualquier otro valor} \end{cases} \quad \text{Ec. 3-27}$$

En la Tabla 3-2 se pueden ver diferentes tipos de kernels. Estos kernels tienen una eficiencia muy parecida al kernel de Epanechnikov, siendo el kernel normal o Gaussiano el menos eficiente de todos.

### NUEVA METODOLOGÍA PLUG-IN

Se utilizará como estimación de densidad de probabilidad la función de apuesta  $f_i(p)$ . En cada iteración la estimación de la función de densidad de probabilidad se calcula usando los  $p$ -valores acumulados:

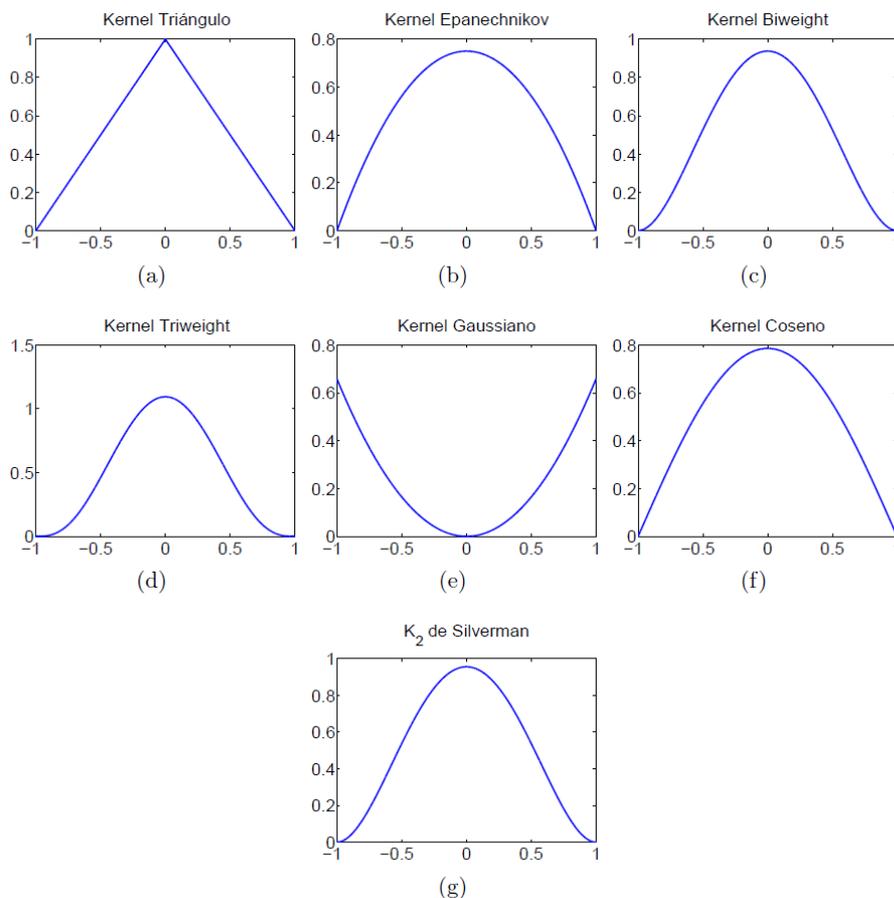
$$p_i(p) = p^\wedge(p_1, \dots, p_{i-1}, p) \quad \text{Ec. 3-28}$$

Donde  $\hat{p}(p_1, \dots, p_{i-1}, p)$  es la estimación de la probabilidad de la función de

densidad usando los  $p$ -valores  $p_1, \dots, p_{i-1}$  generados por el algoritmo 3.1.

Sustituyendo estas funciones de apuesta en Ec. 3-14 se obtiene una nueva martingala llamada *Plug-In* martingale.

Un ejemplo de implementación de este tipo de martingalas es el que a continuación se detalla. Los  $p$ -valores se encuentran siempre en el intervalo  $[0, 1]$ , el método estándar de la ventana de Parzen da resultados pobres para valores que están cerca del límite. Con el fin de obtener mejores resultados para los puntos cercanos al límite, la secuencia de  $p$ -valores se refleja a la izquierda del cero y a la derecha del uno. De modo que la estimación kernel de la densidad se calcula con la muestra extendida  $U_{i=1}^n\{-p_i, p_i, 2 - p_i\}$ . La función de estimación de la densidad se inicializa a cero fuera del intervalo de la unidad y se normaliza mediante la integración a uno. Para los resultados presentados en este trabajo se utilizarán como parámetros el kernel Gaussiano y la NRR (Norma Reference Rule) para el cálculo del valor de  $h$ . Tal y como se comenta en [135] no se han encontrado diferencias utilizando otro tipo de kernels.



**Figura 3-7:** Gráficos de varios kernels que pueden utilizarse para estimar la función de densidad. Test de martingalas para la detección de cambios

Los valores  $S_n$  de las Plug-In Martingales pueden ser actualizados recursivamente. Esto supone calcular los valores de no conformidad  $(\alpha_1, \dots, \alpha_n)$  desde  $(z_1, \dots, z_n)$  para lo cual emplea el tiempo  $g(n)$  y la evaluación de Ec. 3-25 toma un tiempo  $h(n)$ . Con lo cual es fácil colegir que calcular el valor  $\alpha_n$  en el intervalo  $(\alpha_1, \dots, \alpha_n)$  tomará el tiempo  $\Theta(n)$ .

### 3.15. Test de martingalas para la detección de cambios

En esta sección se describirá una arquitectura basada en martingalas para la detección de cambios. En esta arquitectura cuando se observa un nuevo dato se realiza un test de hipótesis para decidir si ha ocurrido un cambio en el modelo que genera el flujo de datos. La decisión está basada en si se produce o no una violación de la presunción de intercambiabilidad utilizando para ello cualquiera de las martingalas descritas en la sección 3.14.5.

#### 3.15.1. Test de hipótesis basado en la regla de máxima desigualdad de Doob

Como se ha comentado con anterioridad, se va a considerar el siguiente test de hipótesis:

$H_0$ : "no hay cambios en el flujo de datos", frente a la alternativa  $H_1$ : "ha ocurrido un cambio en el flujo de datos". Este test se estaría realizando mientras que:

$$0 < M_n^{(\varepsilon)} < \lambda \quad \text{Ec. 3-29}$$

Donde  $\lambda$  es un número positivo. El test rechaza la hipótesis de nulidad  $H_0$  cuando  $M_n^{(\varepsilon)} \geq \lambda$ .

Se supondrá que  $\{M_k: 0 \leq k < \infty\}$  es una martingala no negativa. Si  $E(M_n) = E(M_0) = 1$ , entonces y a partir de la máxima desigualdad de Doob [138],

$$\lambda P\left(\max_{0 \leq k \leq n} M_k \geq \lambda\right) \leq E(M_n), \quad \text{Ec. 3-30}$$

y para cualquier valor de  $\lambda > 0$  y  $n \in \mathbb{N}$ , se tiene que:

$$P\left(\max_{k \leq n} M_k \geq \lambda\right) \leq \frac{1}{\lambda} \quad \text{Ec. 3-31}$$

Esta desigualdad indica que es improbable que el valor de  $M_k$  sea grande. Se rechazará la hipótesis nula cuando el valor de la martingala sea mayor que  $\lambda$ . La desigualdad de la Ec. 3-29 es una cota superior para la ratio de falsas alarmas (FAR – False Alarm Rate), que es una medida de cambios detectados cuando realmente no los hay. El valor de  $\lambda$  es determinado por el FAR que se está dispuesto a aceptar.

### 3.15.2. Test de hipótesis basado en la regla de desigualdad de Hoeffding-Azuma

En [139] se describe una alternativa a Ec. 3-29. En este caso se describe

$$0 < \left| M_n^{(\varepsilon)} - M_{n-1}^{(\varepsilon)} \right| < t \quad \text{Ec. 3-32}$$

donde  $t$  es un número positivo. Se rechaza la hipótesis nula cuando

$$\left| M_n^{(\varepsilon)} - M_{n-1}^{(\varepsilon)} \right| > t \quad \text{Ec. 3-33}$$

**Teorema 3–2: (Desigualdad de Hoeffding-Azuma)** Sean  $c_1, \dots, c_m$  constantes y sea  $Y_1, \dots, Y_m$  una secuencia de diferencias de martingalas con  $|Y_k| \leq c_k$  para cada  $k$ . Entonces para cualquier  $t \geq 0$ ,

$$P \left( \left| \sum_{k=1}^m Y_k \right| \geq t \right) \leq 2 \exp \left( - \frac{t^2}{2 \sum c_k^2} \right) \quad \text{Ec. 3-34}$$

Para usar esta probabilidad destinada a justificar la prueba de hipótesis, se necesita que la diferencia de martingalas esté limitada, es decir  $|Y_i| = |M_i - M_{i-1}| \leq K$ , tal que  $M_i$  y  $M_{i-1}$  son dos valores de martingala consecutivos arbitrarios y  $K \in \mathbb{R}^+$ . Esta condición de diferencia limitada establece que el proceso no da grandes saltos. Además, es poco probable que el proceso deambule lejos de su punto inicial. Por lo tanto, antes de usar Ec. 3-34 para construir el límite superior de probabilidad para justificar el test de martingalas, se necesita mostrar que la diferencia entre dos valores de martingala de *power martingale* está limitada para algunos valores fijos. Se utilizará la *power martingale* determinista en nuestra demostración. Se fijará  $\theta_n = 1$ , para  $n \in \mathbb{Z}^+$  en la función de los  $p$ -valores aleatorio Ec. 3-10. Un  $p$ -valor de salida  $p_n$  es un múltiplo de  $\frac{1}{n}$  entre  $\frac{1}{n}$  y 1.

La diferencia de martingalas es

$$d_n = \prod_{i=1}^{n-1} (\varepsilon p_i^{\varepsilon-1}) (\varepsilon p_n^{\varepsilon-1} - 1) \quad \text{Ec. 3-35}$$

para  $p_n = \frac{u}{n}$ ,  $1 \leq u \leq n$ , si

$$p_n \leq \exp\left(\frac{\log \varepsilon}{1 - \varepsilon}\right) \quad \text{Ec. 3-36}$$

Se tendrá  $d_n > 0$ ; por otro lado  $d_n < 0$ . El  $d_n$  más negativo ocurre cuando  $p_n = 1$  y el  $d_n$  más positivo ocurre cuando  $p_n = \frac{1}{n}$ . Este valor más positivo es más alto que el valor más negativo y, por lo tanto,  $p_n = \frac{1}{n}$  se usará en la condición de diferencia acotada.

Cuando  $m = 1$ , la desigualdad Hoeffding-Azuma de la Ec. 3-34 se convierte en

$$P(|Y_1| \geq t) \leq 2 \exp\left(-\frac{t^2}{2c_1^2}\right) \quad \text{Ec. 3-37}$$

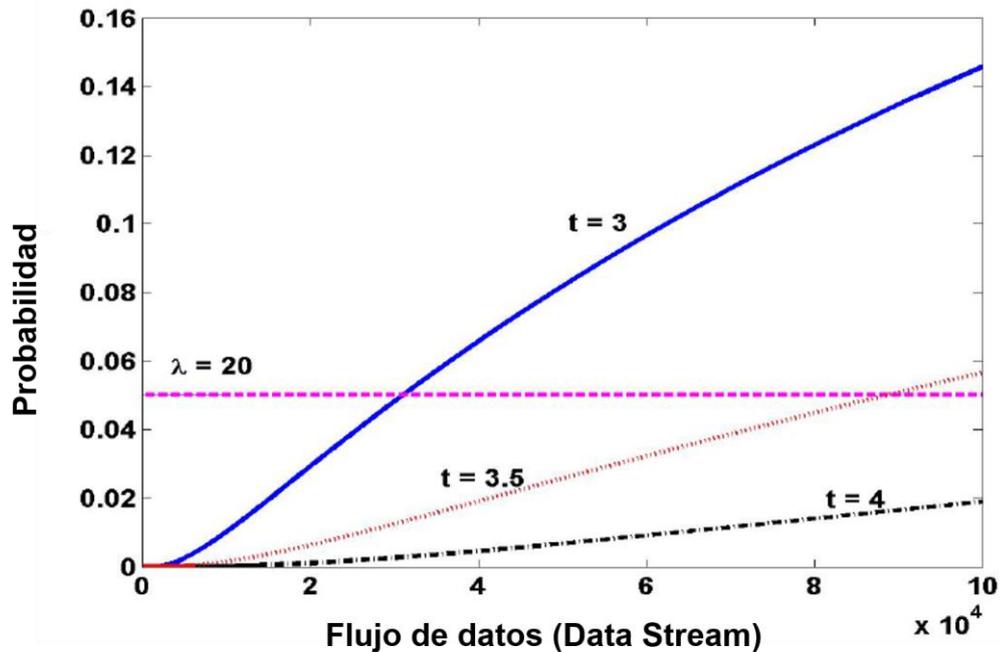
y por lo tanto para cualquier  $n$ ,

$$\begin{aligned} P\left(\left|M_n^{(\varepsilon)} - M_{n-1}^{\varepsilon}\right| \geq t\right) \\ \leq 2 \exp\left(-\frac{t^2}{2\left(\varepsilon\left(\frac{1}{n}\right)^{\varepsilon-1} - 1\right)^2 \left(M_{n-1}^{(\varepsilon)}\right)^2}\right) \end{aligned} \quad \text{Ec. 3-38}$$

Suponiendo que cada paso de prueba es un nuevo paso de prueba basado en una nueva secuencia de martingala, se establecerá el valor de martingala previo  $M_{n-1}^{\varepsilon} = M_0^{\varepsilon} = 1$  en el lado derecho de la desigualdad de la Ec. 3-38. Por lo tanto, se tiene

$$P\left(\left|M_n^{(\varepsilon)} - M_{n-1}^{\varepsilon}\right| \geq t\right) \leq 2 \exp\left(-\frac{t^2}{2\left(\varepsilon\left(\frac{1}{n}\right)^{\varepsilon-1} - 1\right)^2}\right) \quad \text{Ec. 3-39}$$

Si solo se tiene en cuenta  $M_n^{(\varepsilon)} > M_{n-1}^{(\varepsilon)}$ , el límite superior es menor que el lado derecho de la Ec. 3-39. El valor de  $t$  se selecciona de acuerdo con el riesgo que se está dispuesto a tomar.



**Figura 3-8:** Comparación del límite superior de la probabilidad de la diferencia de martingalas para algunos valores  $t = 0.92$ , y el límite superior de probabilidad fija para el valor de martingala cuando  $\lambda = 20$  en una secuencia de datos que consta de 100.000 puntos de datos. Tener un límite superior para la desigualdad máxima de Doob que coincida con el límite superior para un valor  $t$  particular (por ejemplo, 3 - 4) para una  $n$  pequeña (<5000),  $\lambda$  tiene que ser muy grande

### 3.15.3. Algoritmo para el test de martingalas

La metodología de detección de cambios que se propone en el algoritmo 3.2, es una consecuencia directa de la máxima desigualdad de Doob para martingalas. Se puede ver que  $M_i^{(\varepsilon)} = \varepsilon p_i^{\varepsilon-1} M_{i-1}^{(\varepsilon)}$ . Por tanto, no es necesario recalculer  $M(i)$  en el paso 9 para  $p_j, j = 1, \dots, i - 1$ .

Se observa que la desigualdad máxima de Doob de la Ec. 3-30 es en general suficiente para que la Ec. 3-31 sea verdad para cualquier  $k$  entera positiva. Esto significa que la Ec. 3-30 es verdadera mientras que el modelo que genere los datos se mantenga estable.

Sea  $\alpha$  el tamaño del test decidiendo a favor de la hipótesis alternativa  $H_1$  y cuando la hipótesis nula  $H_0$  es verdadera y  $1 - \beta$  es la potencia del test decidiendo a favor de una hipótesis alternativa cuando es verdadera, el test de martingalas de

acuerdo con la Ec. 3-31 que es una aproximación a SPRT (Sequential Probability Ratio Test), con

$$\lambda \leq \frac{1 - \beta}{\alpha} \quad \text{Ec. 3-40}$$

y el tiempo medio de retardo  $E(m)$ . Es decir, el número de ejemplos observados esperados antes de que un cambio es detectado es aproximado por SPRT de la siguiente forma:

$$E(m) \approx \frac{(1 - \beta) \log \lambda}{E(\mathcal{L})}, \quad \text{Ec. 3-41}$$

donde

$$\mathcal{L} = \log \varepsilon p_i^{\varepsilon-1} \quad \text{Ec. 3-42}$$

---

### Algoritmo 3.2 Test de Martingalas

---

**Entrada:**  $M(0) \leftarrow 1; i \leftarrow 1; T \leftarrow \{ \}$  Inicializar valor  $\lambda$

1: **repetir**

2:     Un nuevo ejemplo  $x_i$  es observado

3:     **si**  $T \leftarrow \{ \}$  **entonces**

4:          $x \leftarrow 0$

5:     **si no**

6:         Calcular la medida de extrañeza (ver sección 3.13.3) de  $x_i$  respecto a los elementos procesados de  $T$ .

7:     **fin si**

8:     Calcular los  $p$ -valores  $p_i$  utilizando la Ec. 3-10

9:     Calcular  $M(i)$  mediante la Ec. 3-14

10:    **si**  $M(i) > \lambda$  **entonces**

11:         **DETECTADO CAMBIO**

12:          $M(i) = 1;$

13:         Reinicializar  $T$  a conjunto vacío.

14:    **si no**

15:         Añadir  $x_i$  a  $T$ .

16:    **fin si**

17:     $i \leftarrow i + 1;$

18: **fin repetir**

---

En la Figura 3-10 se muestra un conjunto de datos bidimensional que se utilizará de ejemplo para ilustrar un ejemplo sencillo del TM (Test de Martingala) que permita entender su funcionamiento. Como puede apreciarse estos datos están divididos en 2 grupos compactos y separados. Los datos del grupo C1 aparecen en el conjunto de datos de forma secuencial, a continuación, están los datos del grupo C2. C1 tiene 240 elementos, por lo que el cambio se produce en la lectura del dato nº 241.

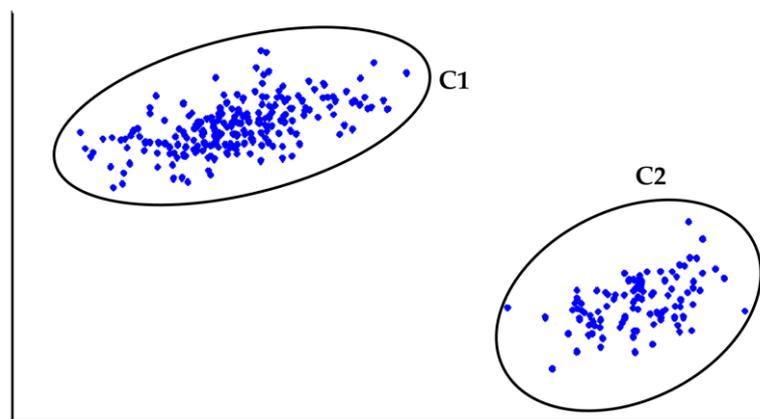


Figura 3-9: Datos de entrada de 2-D

En la Figura 3-10 puede verse el resultado de aplicar el TM a los datos de entrada anteriormente descritos. La línea roja identifica el momento en el que se produce el cambio. En este caso se ha utilizado la Randomized Power Martingale (Ec. 3-18), con  $\lambda = 20$  y  $\varepsilon = 0,85$ . El sistema genera una alarma cuando  $M > 20$ . También se puede apreciar el retardo que se produce entre el momento en el que se produce el cambio y la detección del mismo.

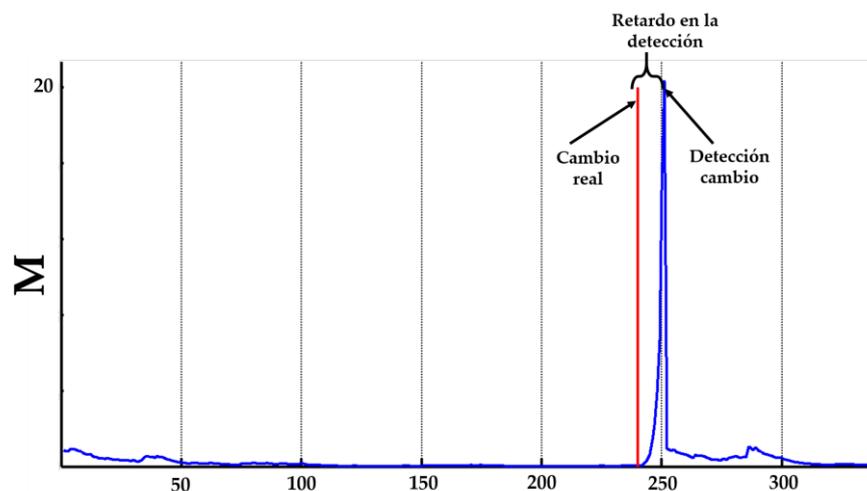


Figura 3-10: En el gráfico puede verse el valor de  $M$  para el conjunto de prueba del ejemplo de la Figura 3-9. El valor de  $\lambda = 20$  y  $\varepsilon = 0,85$

En la Figura 3-11 puede verse la evolución de los diferentes  $p$ -valores para cada ocurrencia de datos. Los  $p$ -valores que se calculan a partir del momento del cambio dejan de ser intercambiables momento en el que la martingala comenzará a “disparar” su valor. En la gráfica se visualiza esta situación en la forma en la que los  $p$ -valores se mantienen en valores muy cercanos al cero, perdiendo la aleatoriedad que representan los datos anteriores a ese momento.

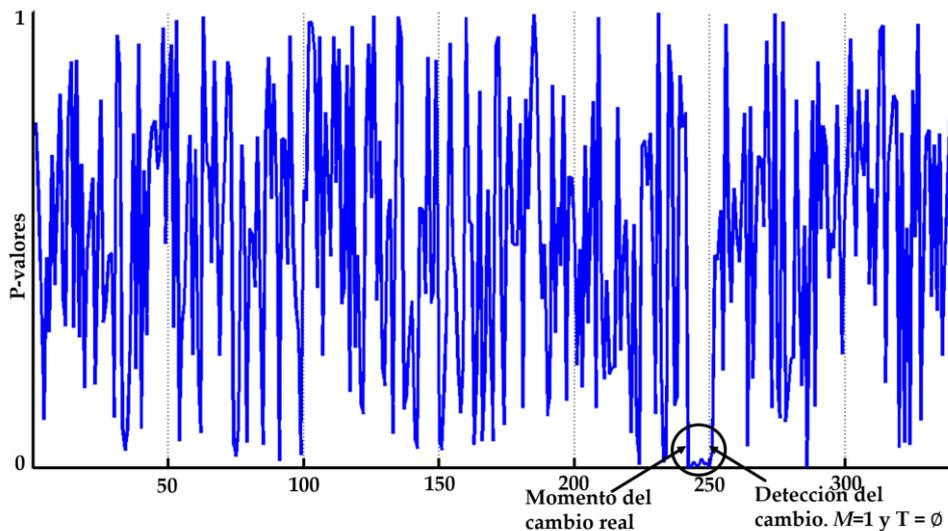


Figura 3-11: Valores de los diferentes  $p$ -valores que se calculan en el ejemplo

Un ejemplo de implementación de este test en MATLAB está disponible en el Anexo A.

#### 3.15.4. Rendimiento del test de martingala

Una parte importante para un algoritmo que quiera analizar un flujo de datos es el rendimiento del mismo. A continuación, se analizará el rendimiento del algoritmo 3.2. Este rendimiento está relacionado con el paso 6 de dicho algoritmo, donde se calcula la *extrañeza* o medida de no conformidad. El cálculo de los  $p$ -valores en el paso 8 puede realizarse con un montículo ordenado cuya complejidad sería  $\mathcal{O}(n \log n)$  y cuyo coste es despreciable frente al coste del cálculo de la *extrañeza* del paso 6.

Un flujo de datos muy grande en el que no se producen cambios hace que la medida de *extrañeza* del  $p$ -valor  $p_i$  tenga que realizarse contra una bolsa  $\{z_1, \dots, z_n\}$  con muchos elementos, lo que computacionalmente es muy costoso. Además, el coste está relacionado con la medida de no conformidad que se seleccione. Una posible solución a este problema podría ser el uso de dos o más test de martingalas los cuales arrancarían y rearrancarían en distintos momentos

del tiempo antes de que se produzca un desbordamiento de memoria o tiempo de ejecución (*time-out*). Un criterio de detección de cambio podría ser o bien el del disparo de la primera alarma o una decisión de un conjunto o secuencia de alarmas que se produzca.

### 3.16. Test de múltiples martingalas utilizando multivistas

A continuación, se sigue lo que se describe en [123]. En el problema de aprendizaje multivista, un ejemplo  $z$  es representado por un número de subconjunto de características. Cada subconjunto de características describe una vista de los ejemplos. El escenario de multivistas está íntimamente relacionado con el coentrenamiento (*co-training*).

Para el test de múltiples martingalas, se considerará el escenario multivista de modo que cada martingala construida intenta identificar cambios con respecto a un subconjunto particular del conjunto de características. Además, por el hecho de que las características son extraídas de los datos originales, el conjunto de características debería ser independiente uno de otro con el objeto minimizar la redundancia.

De acuerdo con la teoría de martingalas, la representación de los datos no afecta al límite de probabilidad.

**Corolario 1.** *Cuando el test de múltiples martingalas con  $M$ -vistas es utilizado para la detección de cambios, el número esperado de datos,  $m$ , observados antes de que se detecte un cambio es,*

$$E_{\mathcal{M}}^*(m) \leq E(m) \quad \text{Ec. 3-43}$$

Por lo que se puede concluir que el número de cambios no detectados utilizando un test de múltiples martingalas está acotado superiormente por el número de detecciones pasadas por alto que se obtiene utilizando el método de una sola martingala. Además, el número de falsas alarmas utilizando el test de múltiples martingalas está acotado inferiormente por el número de falsas alarmas que se obtiene utilizando el método de una sola martingala. El algoritmo 3.3 describe el algoritmo de test de múltiples martingalas utilizando dos vistas. Dicho algoritmo puede ser extendido de forma trivial a  $M > 2$ .

**Algoritmo 3.3** Test de múltiples martingalas con M-vistas,  $M = 2$ 

**Entrada:**  $M_1(0) \leftarrow 1; M_2(0) \leftarrow 1; i \leftarrow 1; T \leftarrow \{ \}$ ; Inicializar valor  $\lambda$

1: **repetir**

2: Un nuevo ejemplo sin etiquetar  $x_i$  es observado

3: Construir las dos vistas/características desde  $x_i$ , ej.:  $\bar{x}_i = \{f_{i1}, f_{i2}\}$

4: Calcular la medida de extrañeza  $\bar{s}_1$  y  $\bar{s}_2$  utilizando la Ec. 3-10 a partir de  $\{f_{11}, f_{i1}\}$  y  $\{f_{12}, f_{i2}\}$ .

5: Calcular  $p$ -valores  $p_1$  y  $p_2$  a partir de  $\bar{s}_1$  y  $\bar{s}_2$ , respectivamente, utilizando Ec. 3-10.

6: Calcular  $M_1(i)$  y  $M_2(i)$  a partir de  $p_1$  y  $p_2$  mediante la Ec. 3-14

7: **si**  $M_1(i) > \lambda$  ó  $M_2 > \lambda$  **entonces**

8: **DETECTADO CAMBIO**

9:  $M_1(i) = M_2(i) = 1;$

10: Reinicializar  $T$  a conjunto vacío.

11: **si no**

12: Añadir  $x_i$  a  $T$ .

13: **fin si**

14:  $i \leftarrow i + 1;$

15: **fin repetir**

# 4. APLICACIONES

---

*“Que algo no funcione como tú esperabas no quiere decir que sea inútil.”*

*Thomas Alva Edison*

## 4.1. Introducción

En este capítulo se describirán tres aplicaciones del algoritmo de detección de cambios basados en martingalas aplicados a la detección de eventos en plasmas termonucleares. Estas aplicaciones son:

1. Detección de cambios en perfiles.
2. Identificación de cambios en diagnósticos de imagen de dispositivos de fusión.
3. Detección de interrupciones.

## 4.2. Detección de cambios en perfiles

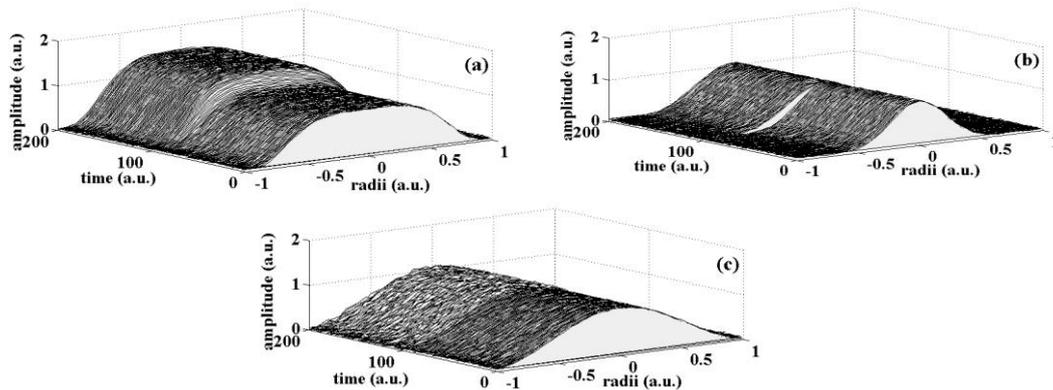
En la operación de plasma de pulso largo (por ejemplo, ITER), el reconocimiento automático de eventos puede ser un problema crucial. Aquí, el término 'evento' se usa para identificar cualquier tipo de cambio en las secuencias de datos, donde 'cambio' significa una diferencia cualitativa en una secuencia de evolución temporal. El reconocimiento automático de cambios es útil no solo en el análisis de datos en tiempo real (por ejemplo, para activar / desactivar la adquisición de señales o para aumentar / disminuir sus tasas de muestreo) sino también en el análisis de datos diferidos (con foco en intervalos de tiempo relevantes a priori).

Este trabajo describe la aplicación a la fusión nuclear de una técnica de propósito general para detectar cambios en flujos de datos variables en el tiempo sin la necesidad de desarrollar implementaciones particulares para cada problema específico. Se basa en una metodología de aprendizaje automático [140], [28]. En cada instante de tiempo, las muestras de datos tienen una representación multidimensional. Por ejemplo, pueden ser un vector cuyos componentes son las amplitudes de diferentes formas de onda o las intensidades de píxeles de una imagen.

Los cambios en los flujos de datos son transiciones de un estado inicial a un estado

final, ambos caracterizados por sus evoluciones particulares. A continuación, se describen las transiciones de estado que se detectarán en esta sección.

La Figura 4-1 son simulaciones de cambios de perfiles radiales a lo largo del tiempo. Dichos perfiles pueden corresponder, por ejemplo, a la temperatura, densidad o radiación del plasma. Los cambios simulados pueden deberse a la inyección de calor adicional, al aumento de impurezas o a la presencia de una mayor actividad de MHD en el plasma.



**Figura 4-1:** Simulación de cambios en flujos de datos. Los cambios mostrados son: (a) cambio suave a una amplitud mayor; (b) mayor ancho; (c) Perfiles con ruido

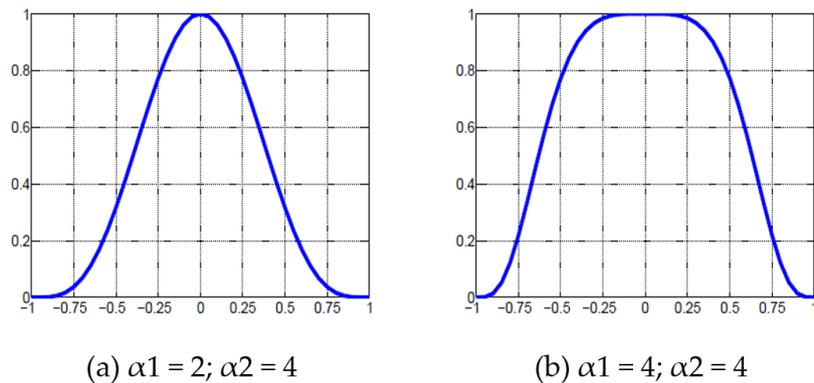
Para la simulación de los perfiles se ha desarrollado un programa en MATLAB que simula los perfiles siguiendo la siguiente ecuación:

$$f(x) = A_0(1 - |r^{\alpha_1}|)^{\alpha_2} \quad \text{Ec. 4-1}$$

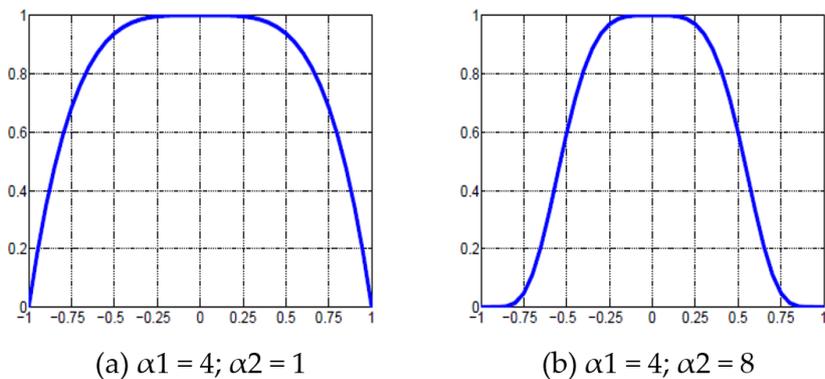
Dónde,

- **$A_0$ :** es la altura de los perfiles.
- **$\alpha_1$ :** será la concentración de los valores centrales de los perfiles o nivel de achatamiento de los perfiles.
- **$\alpha_2$ :** longitud de las colas de los perfiles.

En la Figura 4-2 y Figura 4-3 se pueden observar varios de los efectos que producen estas variables.



**Figura 4-2:** Ejemplos de efectos de la variable  $\alpha_1$  de la Ec. 4-1



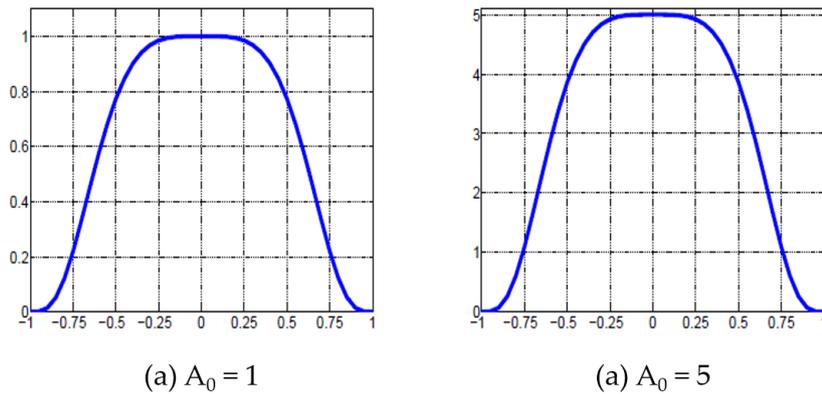
**Figura 4-3:** Ejemplos de efectos de la variable  $\alpha_2$  de la Ec. 4-1

Cada perfil consta de 41 puntos. Además de esto se implementará una serie de variables y funciones que permitirán modificar la generación de perfiles simulados. A continuación, se describen las variables y funciones con las que se va a experimentar:

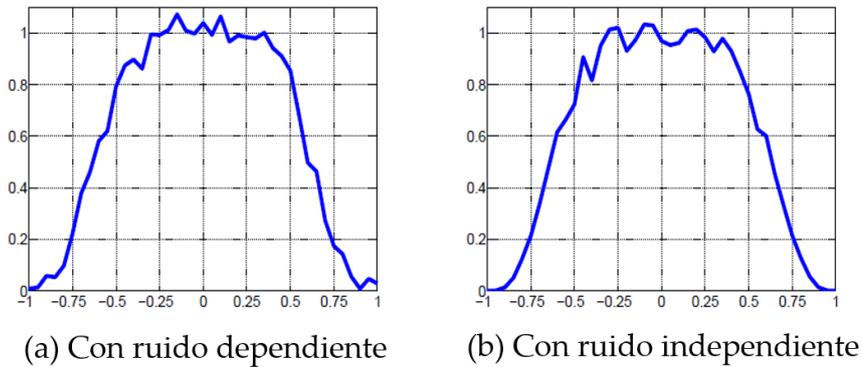
- $A_0$ : Altura de los perfiles.
- **Factor de ruido:** permite simular ruido en los perfiles simulados. Este ruido puede ser a su vez dependiente o independiente de la amplitud de los perfiles simulados.
  - El **ruido independiente** se genera añadiendo a cada perfil el valor resultante de la función  $f(x) = fct \cdot randn$ , donde  $fct$  es el factor de ruido y  $randn$  es una función que genera números aleatorios que siguen una distribución Gaussiana.

- El **ruido dependiente** se genera añadiendo a cada perfil el valor resultante de la función  $f(x) = 1 + fct \cdot randn$ .
- **Factor de suavizado:** suaviza perfiles simulados, a los cuales previamente se les ha añadido un ruido dependiente o independiente de la amplitud de los perfiles. Para ello se han utilizado splines cúbicos.

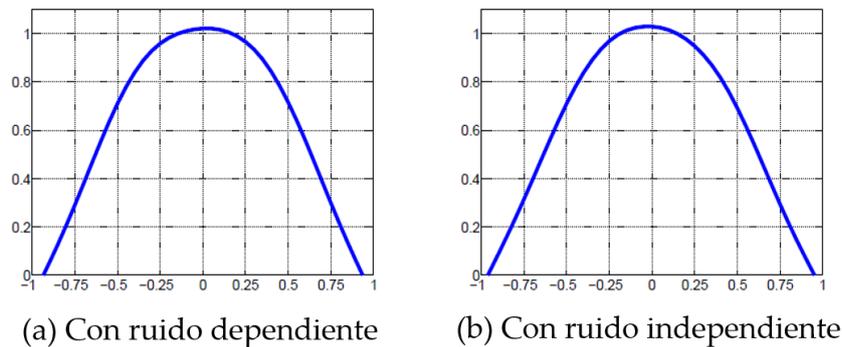
Los efectos de estas variables pueden verse en Figura 4-4, Figura 4-5 y Figura 4-6.



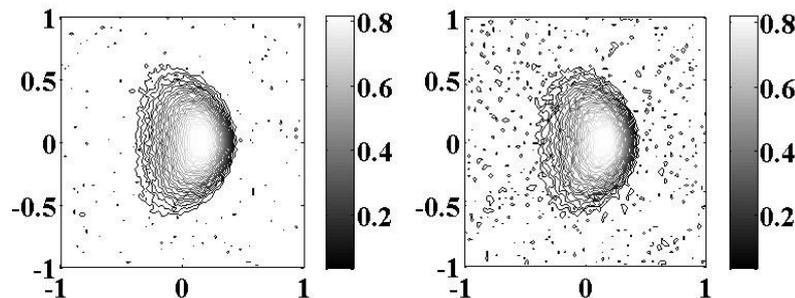
**Figura 4-4:** Ejemplos de efectos de la variable  $A_0$  en la Ec. 4-1



**Figura 4-5:** Ejemplos de efectos de ruido simulado para la Ec. 4-1



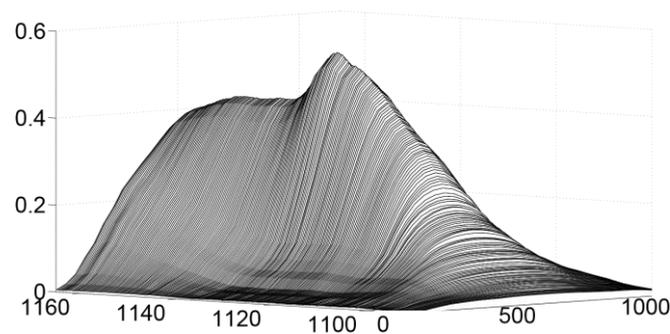
**Figura 4-6:** Ejemplos de suavizado para los casos de la Figura 4-5 con  $\alpha_1 = 4, \alpha_2 = 4$



**Figura 4-7:** Simulación de líneas de contorno de emisión del plasma con diferentes niveles de fluctuación

La Figura 4-7 muestra el cambio del flujo de datos en un problema de dimensión mayor. El objetivo es la detección de variaciones en la distribución espacial de dos dimensiones de la intensidad de emisión del volumen del plasma. El término emisión se utiliza en un sentido amplio y de hecho puede representar diferentes emisiones del plasma tales como emisiones de rayos X blandos, de bolometría o de neutrones. Las emisiones del plasma pueden evolucionar con un nivel de fluctuación particular, por ejemplo, el aumento de la actividad de MHD puede provocar el efecto de elevar el nivel de fluctuación.

La Figura 4-8 muestra la evolución de los perfiles experimentales del stellarator TJ-II [141]. En el estado inicial, la amplitud se incrementa de forma monótona y, en un cierto instante de tiempo, las cuerdas centrales muestran un decremento de la amplitud, manteniendo un valor constante.



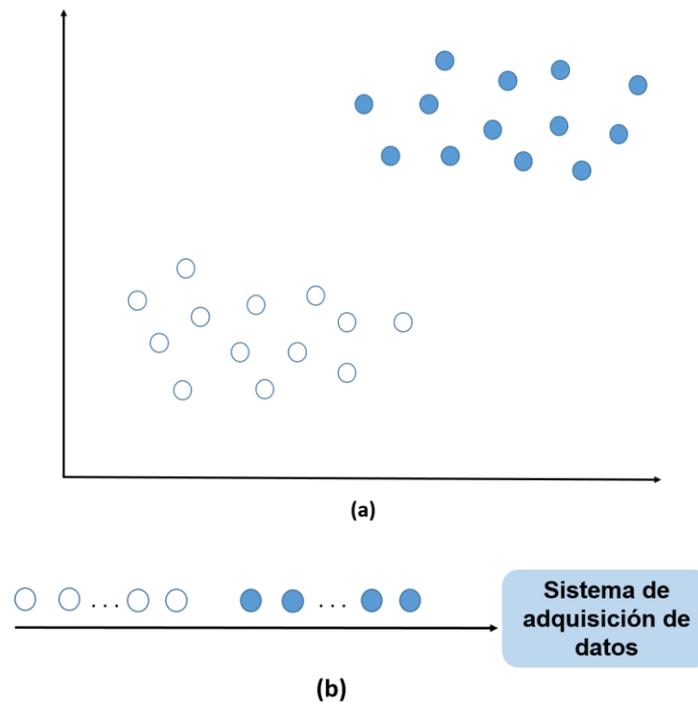
**Figura 4-8:** Evolución temporal de perfiles de bolometría. Perfiles de bolometría del stellarator TJ-II (descarga 21319)

Las descripciones conceptuales y matemáticas de la metodología se presentan en las siguientes secciones donde se describirán los resultados obtenidos con la descarga 21319 del TJ-II. A continuación, se describe la implementación en tiempo real de la metodología en un sistema de adquisición de datos, donde todos los cálculos matemáticos se han implementado en una FPGA.

#### 4.2.1. Descripción del problema y solución conceptual

El algoritmo de reconocimiento para la detección de cambios en flujos de datos debe cumplir los requisitos descritos en la sección 3.9.1.

Para resolver cómo detectar mejor las transiciones de estado, la descripción matemática de los puntos de datos debe formar clústeres separados en el espacio de características. La Figura 4-9, representa datos que se han leído uno a uno, primero todos los de un determinado clúster y luego los del otro. En el momento del cambio (lectura del primer elemento del segundo clúster), el proceso de detección tiene que reconocer que los datos leídos de ahí en adelante son *lejanos* a los datos leídos con anterioridad, momento en el que debe dispararse una alarma de advertencia de dicho cambio.



**Figura 4-9:** (a) Idealmente, el vector de características debería ser seleccionado de forma que los dos estados sean separables en el espacio de características. (b) Los datos son leídos de forma secuencial, uno a uno

#### 4.2.2. Resultados

Desde la Tabla 4-1 a la Tabla 4-6 se mostrará el tiempo de retardo para reconocer las transiciones en los casos representados en la Figura 4-1 con las martingalas: Randomized Power Martingale (RPM), Plug-In Martingale (PIM) y Simple Mixture Martingale (SMM) y  $\lambda = 20$ . Debido al carácter aleatorio de  $\theta_i$  en la Ec. 3-10, cada detección del proceso se ha ejecutado 20 veces para una amplia gama de parámetros:

- RPM:  $0 \leq \varepsilon \leq 1$
- PIM:  $0,5 \leq K_n \leq 2$

Las tablas muestran los rangos  $\varepsilon_{inf.} \leq \varepsilon \leq \varepsilon_{sup.}$  y  $k_{inf.} \leq K_n \leq K_{sup.}$  para las martingalas RPM y PIM respectivamente. En ambos casos, los valores de los parámetros por debajo de los límites inferiores activan falsas alarmas y sobre los límites superiores producen largas demoras o alarmas perdidas. En los rangos que se muestran en las tablas, se han detectado todas las transiciones.

El espacio de características para la representación matemática de perfiles y

emisividad tienen dimensión 2. Las variables específicas son el valor medio y la desviación estándar. Estos valores son suficientes para separar los puntos de datos en dos grupos para reproducir una situación similar a la que se muestra en la Figura 4-9.

**Tabla 4-1:** Perfiles de la Figura 4-1 (a) que han sido distorsionados con ruido Gaussiano  $N(0, 0,1)$  y la amplitud ha sido incrementada un 10%

Martingala	Parámetros	Retardo (#perfiles)
RPM	$0,87 \leq \varepsilon \leq 0,94$	$9 \pm 4$
SMM	-	$7 \pm 4$
PIM	$1,4 \leq K_n \leq 2,0$	$40 \pm 18$

**Tabla 4-2:** Perfiles de la Figura 4-1 (b) que han sido distorsionados con ruido Gaussiano  $N(0, 0,1)$  y el ancho del perfil a media altura se ha incrementado en un 10%

Martingala	Parámetros	Retardo (#perfiles)
RPM	$0,85 \leq \varepsilon \leq 0,88$	$4 \pm 3$
SMM	-	$7 \pm 1$
PIM	$1,5 \leq K_n \leq 1,9$	$25 \pm 10$

**Tabla 4-3:** Perfiles de la Figura 4-1 (c) misma altura pero diferente ruido Gaussiano  $N(0,03, 0,1)$

Martingala	Parámetros	Retardo (#perfiles)
RPM	$0,89 \leq \varepsilon \leq 0,93$	$10 \pm 3$
SMM	-	$9 \pm 3$
PIM	$1,1 \leq K_n \leq 2,0$	$36 \pm 11$

Las tablas anteriores muestran que una sola implementación es lo suficientemente general como para aplicarse al caso de cambios en los perfiles.

Los resultados obtenidos para cada martingala son:

- **Simple Mixture Martingale:**
  1. Detecta los eventos de transición sin la necesidad de ningún parámetro adicional.
  2. La detección se lleva a cabo con pequeños retrasos.
  3. Generalmente produce falsas alarmas.
- **Randomized Power Martingale:**
  1. Es la más rápida de todas en tiempo de ejecución, lo que la haría la más adecuada para aplicaciones en tiempo real.
  2. Detecta correctamente los cambios con retrasos parecidos a SMM.

3. No es posible encontrar un rango común de  $\varepsilon$  que sea válido para todas las situaciones.

- **Plug-In Martingale:**

1. Es la más robusta ya que se ha encontrado un rango común de  $1,5 \leq K_n \leq 1,9$ .
2. El retraso en la detección de la transición es la mayor de todas.
3. Computacionalmente es claramente la más lenta de todas lo que dificultaría su implementación en análisis en tiempo real.

**Tabla 4-4:** Fluctuaciones de emisividad de plasma antes / después de la transición sigue las distribuciones  $N(0, 0,015)$  /  $N(0, 0,020)$  respectivamente

Martingala	Parámetros	Retardo (#perfiles)
RPM	$0,86 \leq \varepsilon \leq 0,94$	15±4
SMM	-	15±1
PIM	$0,5 \leq K_n \leq 1,2$	26±2

Los resultados de la simulación sobre las distribuciones de emisividad se presentan en la Tabla 4-4. Los resultados por tanto son:

- **SMM y RPM**

1. Detectan los cambios.
2. La detección se lleva a cabo con pequeños retrasos.
3. SMM produce falsas alarmas.

- **Plug-In Martingale:**

1. Es la que tarda más en detectar los cambios.
2. El rango del valor de  $K_n$  es demasiado amplio.

Con respecto a los perfiles de bolometría del TJ-II de la Figura 4-8, la detección de la transición también se lleva a cabo en el espacio de características (media, desviación estándar). Sin embargo, para una mejor separación de los clústeres en la forma en la que se ve en la Figura 4-9(a), es necesario preprocesar los perfiles, que han sido obtenidos con una resolución temporal de 100  $\mu$ s. Antes de la transición, la velocidad creciente de los acordes centrales es más o menos constante. Después de la transición, la amplitud permanece constante. La demora

en la detección de la transición es de  $5 \pm 2$  ms.

### 4.2.3. Implementación de Random Power Martingale en una FPGA para la detección de eventos en tiempo real

Los tres casos relacionados con los cambios en los perfiles de la Figura 4-1 se han implementado con la martingala RPM, utilizando la tecnología FlexRIO. La plataforma consiste en una FPGA XILINX integrada en una tarjeta PXI<sup>8</sup>/ PXIe<sup>9</sup> que se puede conectar a diferentes módulos de adquisición de datos de entrada / salida. Las herramientas de software utilizadas para desarrollar la aplicación con hardware FlexRIO son: LabVIEW, LabVIEW para FPGA y herramientas XILINX.

La metodología se ha implementado en una FPGA XILINX siguiendo el procedimiento descrito en [142]. El primer paso ha sido codificar el algoritmo con el lenguaje gráfico de LabVIEW y usar la representación de coma flotante. Después de depurar el código en LabVIEW, se ha optimizado para usar una representación de datos de punto fijo. Esto último es esencial porque los desarrollos en coma flotante en una FPGA son posibles, pero la cantidad de recursos consumidos es muy alta. Los párrafos siguientes describen los pasos llevados a cabo en la FPGA para implementar el algoritmo de test de martingalas descrito en la sección 3.15.3.

Cada punto de un perfil está codificado en una representación de punto fijo con 32 bits, la mitad para la parte entera y la mitad para la parte decimal. Para pasar al espacio de características, se calculan el valor medio y la desviación estándar del perfil. A continuación, se calcula el centroide del grupo y la extrañeza mediante la Ec. 3-8 de los vectores de características. Con las medidas de extrañeza, la Ec. 3-10 se determina con una resolución de 81 bits (17 bits para la parte entera y 64 bits para la decimal). Esta resolución de bits es necesaria para un cálculo preciso de las RPM definidas en la Ec. 3-18. Finalmente, si la Ec. 3-29 se cumple, se analiza un nuevo perfil. De lo contrario, se activa una alarma y el algoritmo se restablece. El método anteriormente descrito es el que aparece de forma detallada en el algoritmo 3.2.

La cantidad total de recursos utilizados para implementar los cálculos en la FPGA (un Virtex 5 SX95T incluido en una tarjeta PXIe-7965R FlexRIO) consiste en: 33.4% de *slices* totales (4917 de 14720); 13.2% del registro de *slices* (7758 de 58880); tablas de búsqueda de *slices* 20.8% (12232 de 58880); 7.0% de DSP48s (45 de 640) y 2.5% de bloque RAMs (6 de 244).

---

<sup>8</sup> PCI eXtensions for Instrumentation

<sup>9</sup> PCI eXtensions for Instrumentation express

Además, es importante tener en cuenta que la FPGA funciona con un reloj de 40 MHz. Finalmente, debe mencionarse que el tiempo promedio de procesamiento por perfil es de aproximadamente 210  $\mu$ s.

El algoritmo en la FPGA ha sido probado para la martingala RPM y los casos que se muestran en la Tabla 4-1, lográndose los mismos resultados.

### **4.3. Identificación de cambios en diagnósticos de imagen de dispositivos de fusión**

Habitualmente los sistemas de medición en fusión son transductores que convierten sus observaciones en señales eléctricas que son digitalizadas y almacenadas para un posterior análisis en diferido (off-line) [29]. El término "señal" en este caso corresponderá a imágenes de video, en bruto o procesadas, desde un sistema de adquisición de datos que en este caso será una cámara de video de alta velocidad. Estas imágenes tienen un contenido de información que permite profundizar en el conocimiento físico del plasma. Un cambio en estas imágenes de evolución temporal es la identificación de alteraciones en el estado del plasma de fusión.

Los sistemas de medición transforman comportamientos físicos en estructuras morfológicas similares (patrones) en las señales. Esto implica que las diferentes fenomenologías presentes en los sistemas físicos pueden ser identificadas mediante el reconocimiento de patrones. Un problema importante en los datos de análisis es la identificación y ubicación de estos patrones dentro de grandes repositorios de datos. La ubicación de los eventos suele ser por métodos no automáticos, por ejemplo, análisis visuales de datos para descubrir la presencia de patrones. Obviamente, este procedimiento está lejos de ser una búsqueda óptima y presenta dos inconvenientes principales.

1. El proceso de análisis es habitualmente muy pesado en términos de horas hombre y, por lo tanto, a menudo no se analizan suficientes casos para conclusiones con una base estadística sólida.
2. La dependencia continua de la intervención humana aumenta la probabilidad de errores humanos, lo que implica problemas de reproducibilidad en los análisis.

La búsqueda automática de patrones en bases de datos masivas se está utilizando con éxito en entornos de fusión nuclear para realizar la recuperación de datos a partir de criterios físicos. Los parámetros de entrada para buscar datos serán los

patrones de señal que caracterizan un comportamiento físico particular. Las salidas de estas técnicas proporcionan un factor de similitud (una distancia en el sentido matemático) para evaluar la semejanza de las señales con el patrón de referencia. Este factor permite ordenar los resultados de búsqueda según el parecido estructural de las señales.

Aplicaciones específicas de los métodos inteligentes de recuperación de datos han sido desarrolladas para las bases de datos de dos dispositivos de fusión, el tokamak JET [143] (el dispositivo de fusión más grande del mundo) y el stellarator TJ-II [55]. Estas aplicaciones particulares proporcionan una interfaz gráfica de usuario para mostrar formas de onda o imágenes. El patrón a buscar es seleccionado por el usuario en una forma de imagen.

Cabe señalar que la recuperación de datos basada en técnicas de reconocimiento de patrones requiere intervención humana para definir formas estructurales específicas para la búsqueda. Sin embargo, los métodos automáticos idealmente sin la participación humana serían de gran ayuda, no solo para la recuperación de datos, sino también para el análisis de bases de datos masivas. Por un lado, permitirían centrar la atención en segmentos de señal interesantes y descartar segmentos de señal irrelevantes. Por otro lado, estos métodos también podrían usarse para la ubicación exacta de eventos singulares en las señales [29].

#### **4.3.1. Sistemas de cámaras de JET**

En el año 2007 se incorporó en JET una cámara APX-RS fotónicamente visible [144], donde el CIEMAT fue responsable de la instalación y mantenimiento de esta cámara. De los varios experimentos de JET-ILW en los que han sido proporcionados como parte del equipo de operación de cámara rápida del visible, dos campos han sido investigados intensivamente en el curso de las campañas C30-C36. Ambos son tareas clave en el camino de la comprensión del comportamiento de un tokamak de grandes dimensiones con paredes de berilio y un divertor de tungsteno: 1) la dinámica de ELM en el divertor y 2) el seguimiento de gas de mitigación de disrupciones. El desarrollo de sistemas de análisis automático de estas imágenes sería de gran utilidad en la operación en tiempo real del dispositivo y su posterior análisis y búsqueda de eventos en bases de datos de imágenes diferidas (off-line).

#### **4.3.2. UMEL (Universal Multi-Event Locator)**

En [29] se describe una técnica novedosa y universal (Universal Multi-Event Locator - UMEL) para la ubicación automática de eventos en formas de onda y

películas de video. En este contexto, "universal" tiene las dos acepciones que se describen a continuación:

1. La técnica es la misma independientemente de los patrones estructurales específicos de las señales y, por lo tanto, no depende de eventos físicos particulares.
2. Es universal por el hecho de que el software que implementa la técnica es igual independientemente del tipo de señales. Esto significa que el software se ha escrito una vez y se aplica exactamente de la misma manera a formas de onda, imágenes o cualquier tipo de señales multivariantes con un número arbitrario de dimensiones. A este respecto, debe destacarse que la selección de parámetros necesarios de un caso a otro puede ser casi automática de acuerdo con algunos criterios generales que se describen en [29].

UMEL intenta buscar automáticamente rastros de eventos dentro de una señal. El proceso de búsqueda es el núcleo de la técnica. UMEL basa sus capacidades de búsqueda en un método de estimación de regresión específico. Entre las diversas técnicas de regresión posibles, UMEL incorpora concretamente máquinas de vector soporte (SVM) [132].

La razón de utilizar los sistemas de aprendizaje se basa en el hecho de que los ajustes resultantes incorporan el contenido de información máximo proporcionado por los datos sin depender de factores tales como, un período de muestreo constante o suposiciones sobre la forma del ruido. La elección de SVM no solo está relacionada con el carácter sólido de sus estimaciones, incluso cuando solo se dispone de datos dispersos, sino también con la posibilidad de proporcionar una interpretación particular a los vectores soporte. UMEL asume que, en general, algunos de los vectores soporte de una regresión representan las muestras más difíciles de regresión y sus coordenadas en el dominio de entrada determinan la ubicación exacta de los eventos físicos. Solo estos vectores soporte son los que llamamos vectores de soporte externos (ESV – External support vectors). La introducción del concepto ESV es innovadora y es la base de UMEL.

#### 4.3.2.1. SVM para regresión

SVM es un procedimiento de aprendizaje constructivo universal basado en la teoría del aprendizaje estadístico [126]. SVM se desarrolló inicialmente para el problema de clasificación en datos separables. Más tarde se mejoró para manejar datos no separables e igualmente se adaptó para resolver el problema de regresión.

Sean  $S$  ejemplos de entrenamiento  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_S, y_S)$ ,  $[\mathbf{x}_i \in \mathbb{R}^n$  y  $y_i = f(\mathbf{x}_i)$  donde  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ ]. La función de regresión es dada por [127]

$$f^*(\mathbf{x}) = \sum_{k=1}^S \gamma_k^* H(\mathbf{x}_k, \mathbf{x}) \quad \text{Ec. 4-2}$$

El parámetro  $\gamma_k^*$ ,  $k = 1, \dots, S$ , están determinados a partir de la solución del siguiente problema de optimización cuadrático:

$$\gamma_k^* = \alpha_k^* - \beta_k^*, \quad k = 1, \dots, S \quad \text{Ec. 4-3}$$

Dónde los parámetros  $\alpha_k^*, \beta_k^*$ ,  $k = 1, \dots, S$  son determinados por la función de maximización:

$$\begin{aligned} Q(\alpha, \beta) = & -e \sum_{k=1}^S (\alpha_k + \beta_k) \\ & + \sum_{k=1}^S y_k (\alpha_k - \beta_k) \\ & - \frac{1}{2} \sum_{k,l=1}^S (\alpha_k - \beta_k)(\alpha_l - \beta_l) H(\mathbf{X}_k, \mathbf{X}_l) \end{aligned} \quad \text{Ec. 4-4}$$

Y las restricciones:

$$\sum_{k=1}^S \alpha_k = \sum_{k=1}^S \beta_k, \quad 0 \leq \alpha_k \leq \frac{C}{S}, \quad 0 \leq \beta_k \leq \frac{C}{S}, \quad k = 1, \dots, S, \quad \text{Ec. 4-5}$$

Dados los datos de entrenamiento  $(\mathbf{x}_k, y_k)$ ,  $k = 1, \dots, S$ , un kernel  $H$  de producto interno, una zona insensible  $e$  y un parámetro de regularización  $C$ .

Diferentes combinaciones de kernels, e-valores, y parámetros de regularización permiten determinar varios grados de suavizado en las estimaciones de regresión.

#### 4.3.2.1.1. Kernels para estimar funciones de valor real

Para construir diferentes tipos de SVM, se pueden elegir diferentes núcleos  $H(\mathbf{x}, \mathbf{x}')$  para propósitos de regresión. En particular, los kernels que normalmente se usan para la clasificación también se pueden adoptar para las tareas de regresión. Ejemplos de estos son los núcleos que generan polinomios

$$H(\mathbf{x}, \mathbf{x}') = [(\mathbf{x} \cdot \mathbf{x}') + 1]^d,$$

kernels que generan RBFs,

$$H(\mathbf{x}, \mathbf{x}') = H(|\mathbf{x} - \mathbf{x}'|),$$

tal como

$$H(|\mathbf{x} - \mathbf{x}'|) = e^{-\frac{|\mathbf{x} - \mathbf{x}'|^2}{2\sigma^2}} \quad \text{Ec. 4-6}$$

O kernels generados por una red neuronal de dos capas,

$$H(\mathbf{x}, \mathbf{x}') = \tanh[v(\mathbf{x} \cdot \mathbf{x}') + a]$$

En algunas aplicaciones de regresión, puede ser necesario el desarrollo de núcleos especiales que reflejen propiedades especiales de las funciones de aproximación [126]: núcleos que generan expansión en polinomios ortogonales, núcleos que generan splines y núcleos que generan expansiones de Fourier.

#### 4.3.2.1.2. Zona e-insensible

La calidad de la aproximación producida por una máquina de aprendizaje se mide por la función de pérdida  $L[y, f(x)]$  o la discrepancia entre la salida producida por el sistema y la máquina de aprendizaje para un punto dado  $\mathbf{x}$ . Por convención, la pérdida toma valores no negativos, de modo que los valores positivos grandes corresponden a una aproximación pobre. La formulación de regresión para SVM utiliza una función de pérdida especial. Esta función de pérdida es lineal con una zona insensible  $e$ .

$$L(y, f(x)) = \begin{cases} 0, & \text{Si } |y - f(x)| \leq e \\ |y - f(x)| - e, & \text{En cualquier otro caso} \end{cases} \quad \text{Ec. 4-7}$$

La función de pérdida es igual a 0 si la discrepancia entre los valores pronosticados y los observados es menor que  $e$ . La zona insensible  $e$  proporciona el nivel requerido de precisión  $e$  para aproximar una función  $f(x)$  por otra función  $f^*(x)$  tal que la función  $f(x)$  está situada en el  $e$ -tubo de  $f^*(x)$ . El eje del tubo define una  $e$ -aproximación  $f^*(x)$  de la función  $f(x)$ .

#### 4.3.2.1.3. Regularización del parámetro C

En estadística y en aprendizaje automático, la regularización se utiliza para evitar el sobreajuste. El aprendizaje es el proceso de estimar una dependencia desconocida del tipo entrada-salida utilizando un número limitado de

observaciones. El reto en la regresión es estimar los valores de puntos diferentes a los de entrenamiento. La generalización es la capacidad del sistema de estimar nuevos puntos que no se usaron en la fase de entrenamiento. Para una buena capacidad de generalización, se debe evitar el sobreajuste.

#### 4.3.2.1.4. Vectores Soporte

Solo un subconjunto de los parámetros  $\gamma_k^*$  en la Ec. 4-2 es distinto de cero. Los puntos de datos  $\mathbf{x}_k$  asociados con el valor no cero de  $\gamma_k^*$  se llaman vectores de soporte. Por lo tanto, la función de regresión es en realidad

$$f^*(\mathbf{x}) = \sum_{\text{Vectores soporte}} \gamma_k^* H(\mathbf{x}_k, \mathbf{x}) \quad \text{Ec. 4-8}$$

Se puede tener en cuenta las siguientes consideraciones empíricas [29]:

1. El aumento de los  $\epsilon$ -valores producen estimaciones más suaves, pero con menos precisión.
2. A medida que  $\epsilon$  aumenta, se obtienen menos vectores soporte, pero son subconjuntos de los que aparecen con  $\epsilon$ -tubos más estrechos.
3. Los vectores soporte son muestras que tienden a ser las más difíciles de regresión. Por un lado, corresponden a muestras dentro o fuera de los límites del  $\epsilon$ -tubo. Por otro lado, si están dentro del  $\epsilon$ -tubo, los vectores soporte aparecen en áreas de alta curvatura o cerca de los límites del intervalo.
4. Los vectores soporte son independientes de la función del kernel. Estas conclusiones específicas son de validez general en los problemas de regresión de SVM. Por lo tanto, sugieren que los vectores de soporte están vinculados a ciertas características morfológicas de las señales. En particular, pueden conectarse con las muestras más difíciles de regresión.

El último punto que se acaba de comentar es la idea central de UMEL porque estas propiedades de los vectores soporte son la base sobre la que se fundamenta el localizador automático de eventos dentro de las señales.

#### 4.3.2.2. Conclusiones de UMEL

El objetivo de UMEL es la ubicación automática de cualquier tipo de evento dentro de cualquier clase de señal. La formulación de estimaciones de regresión con SVM, Ec. 4-2, es válida para cualquier número de dimensiones. Por esta

razón, se puede usar UMEL en espacios de características cuyas muestras pueden tener cualquier cantidad de componentes.

La Ec. 4-2 expresa el hecho de que la regresión con SVM de conjuntos de datos complejos puede requerir de todas las muestras para obtener un modelo de regresión. Por otro lado, debería tenerse en cuenta que la complejidad de una función puede ser definida en términos de su suavidad, ya que para funciones más suaves se requieren menos puntos de datos para una estimación precisa. Justamente este es el significado de la Ec. 4-8. Cuanto más suave sea la función que se quiere obtener mediante una regresión, menos vectores soporte se requerirán.

En una estimación de regresión con SVM, todas las muestras de señal que se encuentran sobre y hacia afuera del  $\epsilon$ -tubo son vectores soporte. En [29] se refiere a ellos como ESV (External Support Vectors). Adicionalmente, algunas muestras dentro del  $\epsilon$ -tubo se convierten en vectores soporte, que se denominan ISV (Internal Support Vectors). Los ISV son muestras necesarias para el cálculo de la regresión, Ec. 4-8, pero no proporcionan el grado de relevancia que se puede asignar a los ESV. Debido al hecho de que las regresiones SVM tienden a ser suaves dentro de la zona  $\epsilon$ -insensible, una interpretación original de los vectores soporte es propuesta por los autores: las muestras que se convierten en ESV son las muestras más difíciles de regresar (no se pueden ajustar dentro de un  $\epsilon$ -tubo suave) y estas muestras proporcionan información adicional esencial en el proceso de regresión. Los ESV revelan la aparición de patrones especiales dentro de una señal: picos, altos gradientes o segmentos con diferentes morfologías, cambios en imágenes, etc.

Por un lado, los puntos singulares muestran una firma con una fuerte ubicación en el dominio de la señal y, por lo tanto, definen segmentos cortos. Por otra parte, grandes secuencias de ESV denotan la presencia de intervalos de señal con patrones claramente diferenciados del resto de la señal.

En una regresión con SVM, potencialmente tres parámetros libres afectan a la complejidad del modelo final:

1. El parámetro de regularización  $C$ .
2. Los parámetros del kernel,  $\sigma$ .
3. El  $\epsilon$ -valor.

Las diversas combinaciones entre ellos determinan las diferentes selecciones del modelo. En la Figura 4-10 se muestra un ejemplo de salida para unos valores de

los parámetros comentados anteriormente.

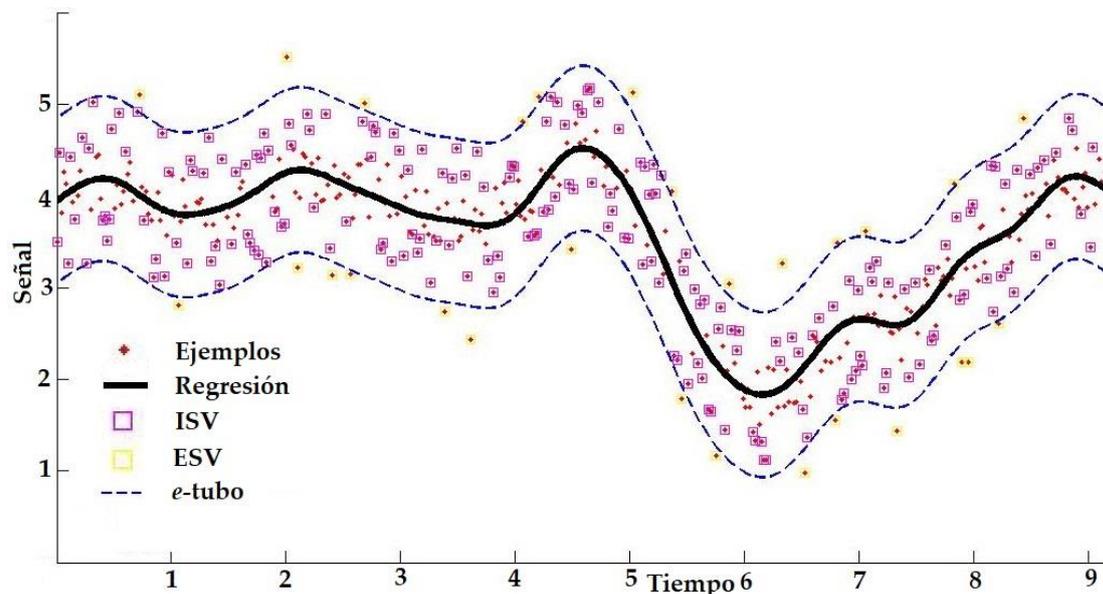


Figura 4-10: Ejemplo de función de SVR;  $C=20$ ,  $s=0,5$ ,  $\epsilon$ -valor =  $0,9$

UMEL no se restringe a identificar amplios segmentos de datos. Se puede utilizar igualmente para la localización exacta de puntos singulares.

Como ejemplo, UMEL se ha aplicado en JET para el reconocimiento y la ubicación de dos eventos diferentes relacionados con la física del plasma: dientes de sierra y disrupciones.

### 4.3.3. Tratamiento de imágenes con UMEL y el Test de Martingalas

A continuación, se utilizará UMEL y el test de martingalas descrito en el algoritmo 3.2 para la identificación de eventos en imágenes de JET. Posteriormente se hará una comparativa de rendimientos entre ambos métodos.

Para el test se utilizarán 4 películas correspondientes a distintas descargas de JET, en la Figura 4-11 se puede ver un fotograma de cada una de ellas, donde se puede observar que son imágenes en blanco y negro del espectro de radiación visible del plasma. En este caso la radiación en el visible se produce cuando el plasma de fusión sufre una pérdida de temperatura.

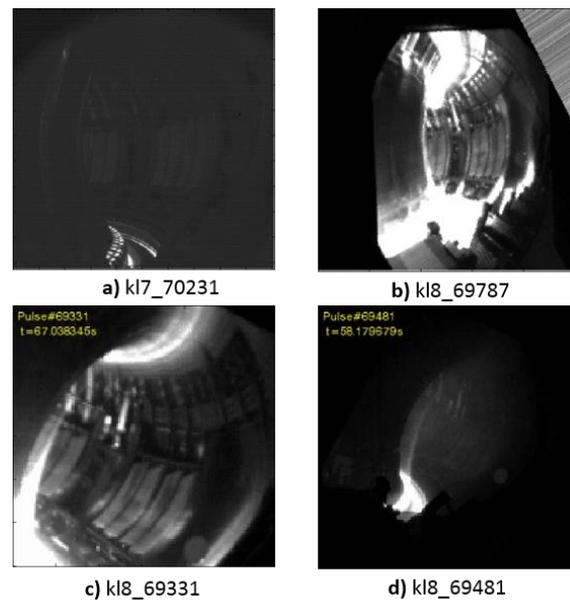


Figura 4-11: Fotogramas de los 4 videos que se utilizan en el estudio

A continuación, se detalla el número de fotogramas de cada una de ellas:

- **kl7\_70231:** 299 fotogramas.
- **kl8\_69331:** 1.838 fotogramas.
- **kl8\_69481:** 599 fotogramas.
- **Kl8\_69787:** 1.110 fotogramas.

Previamente a la aplicación de ambos métodos (UMEL y Martingalas) se ha realizado un preprocesado de cada fotograma de cada uno de los videos. Concretamente se ha utilizado un filtro de medias de cada pixel para grupos de pixel dentro del entorno de vecindad definida por una matriz 5x5. Dada una imagen  $f(i, j)$ , el procedimiento consiste en generar una nueva imagen  $g(i, j)$  cuya intensidad para cada píxel se obtiene promediando los valores de intensidad de los píxeles  $f(i, j)$  incluidos en un entorno de vecindad predefinido. Para una descripción de este método se puede consultar [145].

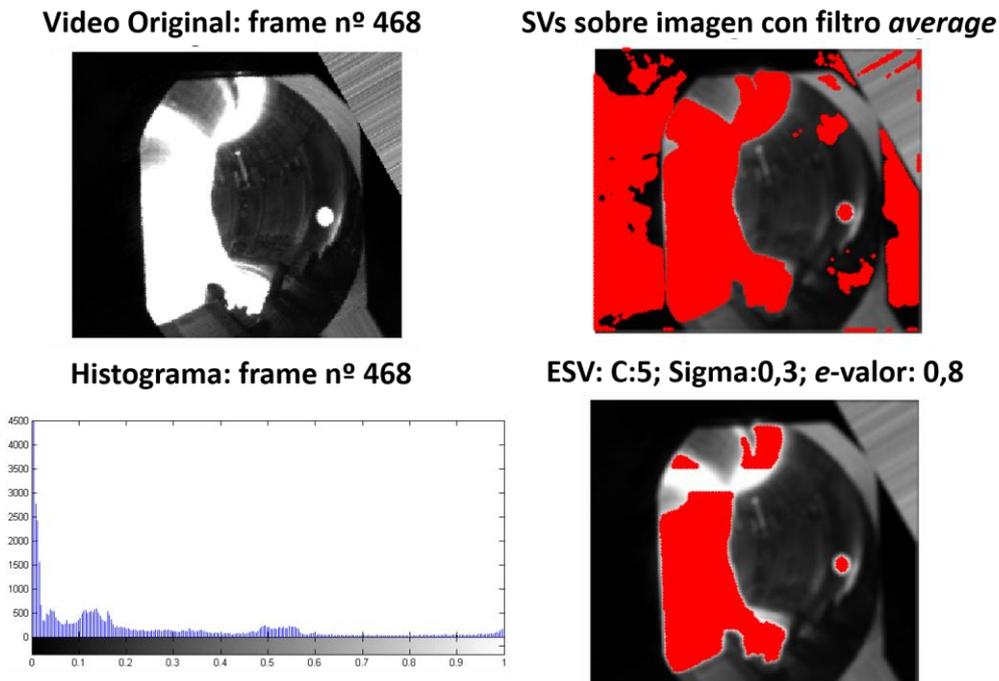
Los resultados que se muestran a continuación se realizaron sobre un ordenador con Procesador Intel(R) Core(TM) i5-6300U CPU @ 2.40GHz, 2401 Mhz, con 2 procesadores principales y 4 procesadores lógicos.

#### 4.3.3.1. UMEL

Para el caso de UMEL se han probado varios valores de  $C$ ,  $\sigma$  y  $e$ -valor para un

kernel de tipo *rbf*, eligiendo aquellos valores que proporcionan un equilibrio entre rendimiento y precisión. Los valores finalmente seleccionados fueron:

- $C = 5$ .
- $\sigma = 0,3$ .
- $e$ -valor = 0,8.



**Figura 4-12:** Ejemplo tratado con UMEL en el que pueden verse los SVs y ESVs

Una vez obtenidos los ESV se vuelve a ejecutar UMEL para un kernel de tipo *poly*. Los resultados se pueden ver en la Tabla 4-5.

**Tabla 4-5:** Resultado Final UMEL

Video	# Cambios detectados	Tiempo de ejecución (min.)	# Fotogramas
K17_70231	2	30,96	299
K18_69331	4	8.052,04	1.839
K18_69481	7	1.566,36	599
K18_69787	3	4.690,52	1.110

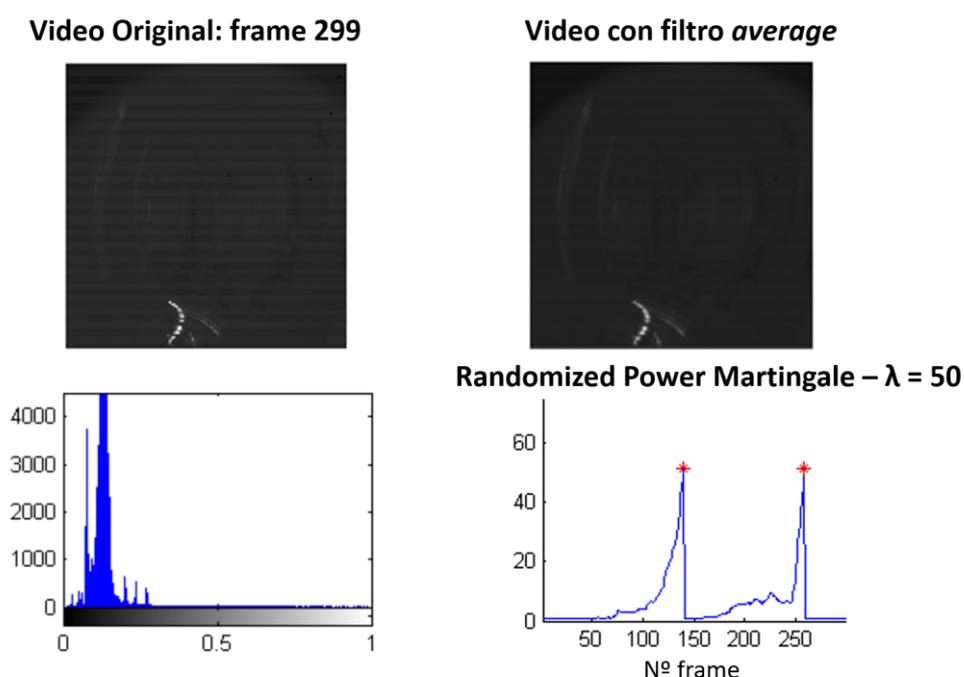
#### 4.3.3.2. Test de Martingalas (TM)

Para el caso del TM, se han realizado varias pruebas comprobándose que los mejores valores, con un compromiso entre falsas alarmas y velocidad de respuesta son para  $\lambda = 100$ . Dado el carácter estocástico del algoritmo se han realizado tandas de 10 ejecuciones para corroborar los resultados.

Los pasos que se siguen en el modelo del test de martingalas para la construcción del vector de características que se usará de entrada en el test de martingalas son los siguientes para cada fotograma:

1. Filtrado de imagen mediante filtro de medias descrito en la sección 4.3.3.
2. Cálculo del histograma de intensidad de la imagen en blanco y negro.

En la Figura 4-13 puede verse un fotograma del resultado final del proceso para uno de los videos descritos con anterioridad.



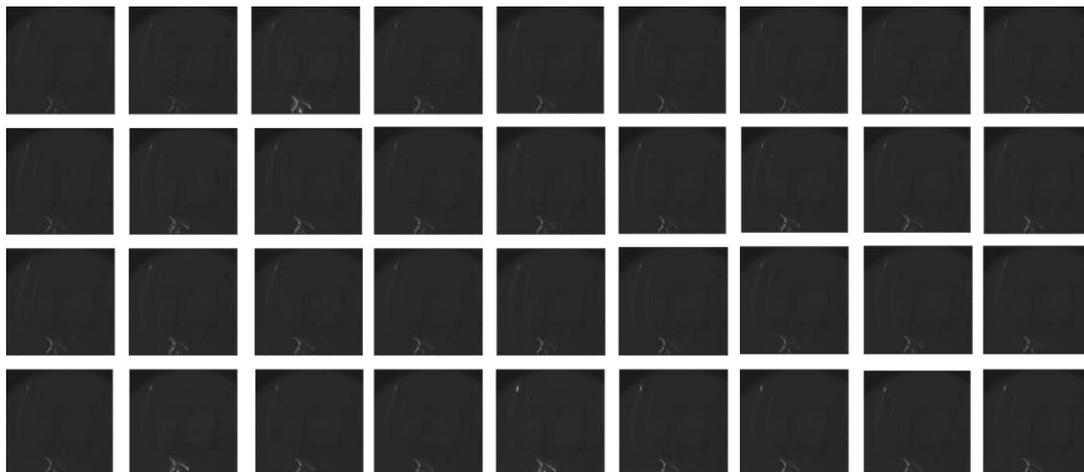
**Figura 4-13:** TM para el video kl7\_70231. RPM para  $\lambda = 50$  y  $\varepsilon = 0,95$

Por otro lado, se puede ver el resultado de tiempos de ejecución del test de martingalas en la Tabla 4-6. Se observa que los tiempos de ejecución son mucho más eficientes que los obtenidos con UMEL. Como ejemplo más destacado puede verse el caso del video kl8\_69331 que en el peor de los casos (PIM) tarda 5,583 minutos mientras que con UMEL se necesitaron 5,59 días. Esta diferencia tan ostensible de rendimiento en tiempo de ejecución hace especialmente adecuado el test de martingalas para aplicaciones en tiempo real. Si analizamos cada martingala se aprecia que RPM es la más rápida, salvo para el caso de kl8\_69787 donde SMM la supera por un escaso margen. En el caso contrario se tiene a PIM que es en todos los casos analizados la más lenta.

**Tabla 4-6:** Tiempos de ejecución para  $\lambda = 100$ ;  $\varepsilon = 0,95$ 

Video	Martingala	Tiempo ejecución (min.)	#Fotograma
kl7_70231	RPM	0,121	299
	SMM	0,103	
	PIM	0,149	
kl8_69331	RPM	3,797	1.839
	SMM	4,302	
	PIM	5,583	
kl8_69481	RPM	0,583	599
	SMM	0,584	
	PIM	0,742	
kl8_69787	RPM	0,490	1.110
	SMM	0,454	
	PIM	1,061	

## 4.3.3.2.1. Video kl7\_70231

**Figura 4-14:** Fotogramas desde el 133 al 168 para el video kl7\_70231**Tabla 4-7:** Resultados para video kl7\_70231

Martingala	Parámetros	Retardo (#fotogramas)	#Cambios detectados
RPM	$0,91 \leq \varepsilon \leq 0,93$	1±12	2±3
SMM	-	40±49	2±3
PIM	$1 \leq K_n \leq 1,3$	1±12	2±4

A la vista de estos resultados puede decirse que RPM y PIM funcionan para un rango pequeño de valores paramétricos (el resto genera falsas alarmas, no detecta el cambio, o genera mayor retardo) y tienen el mismo retardo. SMM detecta muy tarde los cambios, comparado con el resto de martingalas, y genera falsas alarmas.

## 4.3.3.2.2. Video kl8\_69331

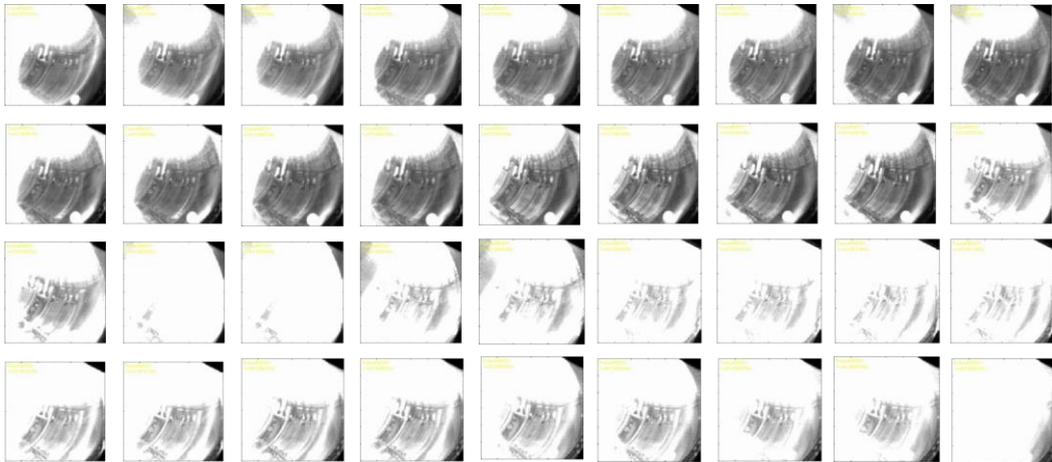


Figura 4-15: Fotogramas desde el 1.485 al 1.520 para el video kl8\_69331

Tabla 4-8: Resultados para video kl8\_69331

Martingala	Parámetros	Retardo (#fotogramas)	#Cambios detectados
RPM	$0,90 \leq \varepsilon \leq 0,93$	$3 \pm 30$	$14 \pm 17$
SMM	-	$7 \pm 11$	25
PIM	$1,6 \leq K_n \leq 1,9$	$3 \pm 37$	$29 \pm 32$

Tanto RPM como PIM funcionan para un rango pequeño de valores paramétricos (el resto genera falsas alarmas, no detecta el cambio, o genera mayor retardo). PIM y RPM tienen un rango de retardo similar.

## 4.3.3.2.3. Video kl8\_69481

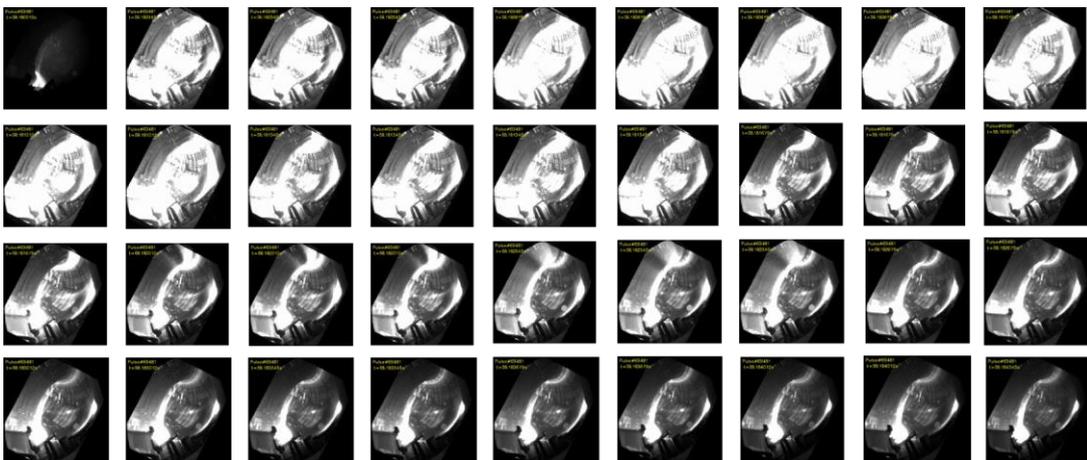


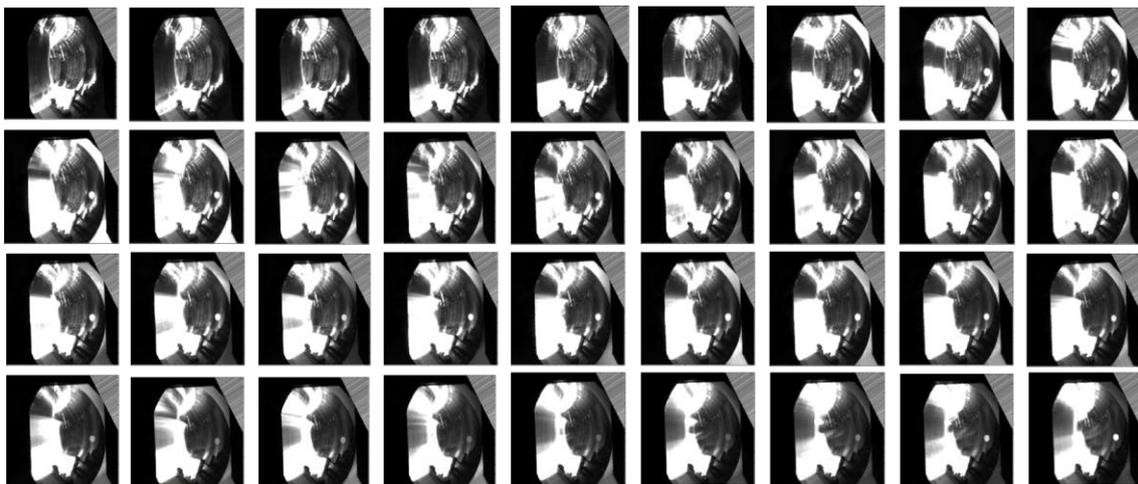
Figura 4-16: Fotogramas desde el 203 al 238 para el video kl8\_69481

**Tabla 4-9:** Resultados para video kl8\_69481

Martingala	Parámetros	Retardo (#fotogramas)	#Cambios detectados
RPM	$0,90 \leq \varepsilon \leq 0,94$	2±10	2±5
SMM	-	2	5±11
PIM	$1,6 \leq K_n \leq 2$	6±22	5±6

Tanto RPM como PIM funcionan para un rango pequeño de valores paramétricos (el resto genera falsas alarmas, no detecta el cambio, o genera mayor retardo). SIM es la que tiene menor retardo aunque similar a RMP cuanto más cercana sea  $\varepsilon$  al valor 0,90. Respecto al número de cambios, concuerda con los eventos presentes en las imágenes, salvo en el caso de SMM que suele arrojar mayor número de falsas alarmas que el resto.

#### 4.3.3.2.4. Video kl8\_69787

**Figura 4-17:** Fotogramas desde el 796 al 831 para el video kl8\_69787**Tabla 4-10:** Resultados para video kl8\_69787

Martingala	Parámetros	Retardo (#perfiles)	#Cambios detectados
RPM	$0,9 \leq \varepsilon \leq 0,92$	9±27	5±7
SMM	-	8±20	9±12
PIM	$K_n \in [0,66, 1,66] \cup [1, 5, 1,66]$	2±20	4±18

#### 4.3.3.3. Conclusiones

Tras analizar 4 videos de JET tanto con UMEL como con TM se puede extraer las siguientes conclusiones:

- Desde un punto de vista de costo computacional, TM es ostensiblemente más

eficiente que UMEL. Esta característica haría a TM mucho más idóneo para el análisis *On-Line* de imágenes, como puede ser el caso de las cámaras de alta velocidad de JET que se han descrito en la sección 4.3.1.

- UMEL necesita de “dos pasadas” del algoritmo para detectar los cambios significativos. Esta característica dificulta su implementación en sistemas de tiempo real. Por el contrario, TM es un algoritmo de “una sola pasada” lo que favorece su implementación y mejor rendimiento en este tipo de sistemas.
- TM detecta mejor los cambios sutiles o varios cambios en momentos cercanos del tiempo. UMEL tiende a quedarse con los cambios más significativos de cada video.
- Para el caso de TM, pueden hacerse las siguientes consideraciones entre martingalas:
  - RPM y PIM, son las que dan mejor resultado teniendo en cuenta retardos, falsas alarmas y cambios no detectados.
  - RPM es computacionalmente menos costosa que PIM.
  - PIM detecta en general más cambios que RPM.
  - El valor de  $0,91 \leq \varepsilon \leq 0,92$  para RMP que da mejor desempeño en todos los casos. Para el caso de RMP sería valores  $1,5 \leq k \leq 1,6$ .
  - SMM tiende a generar falsas alarmas.

#### **4.4. Detección de interrupciones: SPAD (Single signal Predictor based on Anomaly Detection)**

Como se ha visto en la sección 2.6, las interrupciones son el mayor problema que presentan los dispositivos nucleares de tipo tokamak. Este fenómeno es inevitable y produce fuertes fuerzas electromagnéticas, electrones desacoplados (runaway electrons) y fuertes cargas térmicas que ponen en serio riesgo la integridad del dispositivo nuclear.

Como se ha comentado con anterioridad, se han desarrollado y testado varias técnicas que mitigan estas interrupciones, como pueden ser la inyección masiva de gas, de pastillas de terminación de la fusión (killer pellet) o calentamiento mediante resonancia de sincrotrón de electrones. Todas estas técnicas necesitan ser lanzadas con tiempo suficiente de antelación para que se puedan llevar a cabo,

10 ms en el caso de JET. Para el caso de ITER es necesario desarrollar predictores con una ratio de éxito en la detección superior al 95% y una ratio de falsas alarmas inferior al 5%.

#### 4.4.1. SPAD (Single signal Predictor based on Anomaly Detection)

SPAD (Single signal Predictor based on Anomaly Detection) descrito en [30] fue previamente nombrado como PBOD en [31], [32] y [33].

SPAD utiliza una única señal llamada Locked Mode (LM). Esta señal está estrechamente relacionada con el comportamiento disruptivo y este predictor muestra una buena relación entre las anomalías en la señal y las interrupciones. Aunque SPAD es un predictor de caja negra (no explica los resultados que ofrece), utiliza una sola señal en el dominio del tiempo vinculado a la fenomenología física, lo que permite que se entienda bien por parte de un usuario científico.

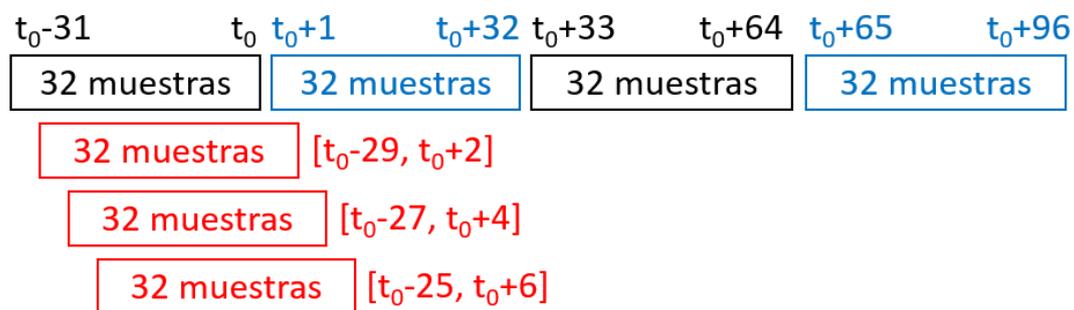
##### 4.4.1.1. Generación del vector de características

La señal LM (Locked Mode) se lee cada 1 ms y las últimas 32 muestras son procesadas cada 2 ms. El predictor usa la información de tiempo y frecuencia de LM obtenida por medio de una transformada wavelet. En particular, se utilizan los coeficientes de aproximación de la transformada Haar Wavelet. Estos coeficientes se utilizan como un vector de características.

Tamaño de la ventana: 32 ms

Ratio de las muestras: 1kS/s

Ventana deslizante: 2 ms

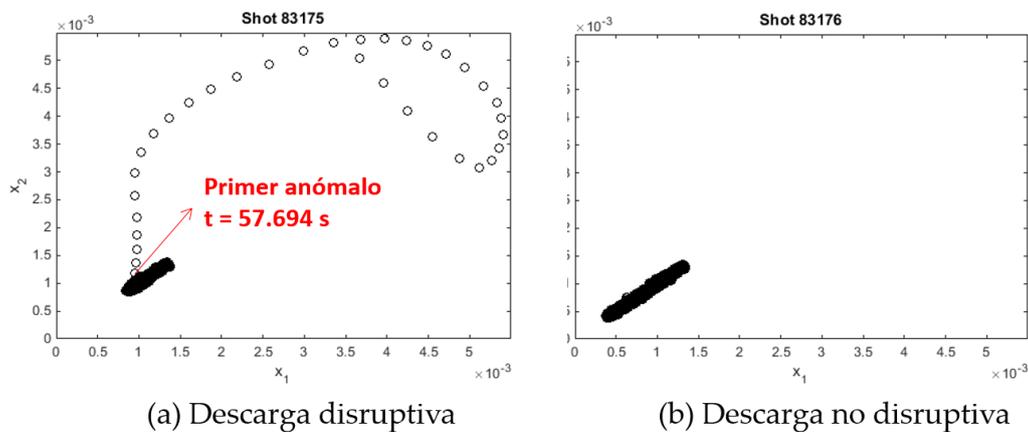


**Figura 4-18:** Explicación de muestras de señales de empaquetamiento en ventanas deslizantes. Ejemplo de la distribución de muestras en ventanas de 32 elementos con deslizamiento de 2 ms

La representación de este vector como un punto en un espacio multidimensional (Figura 4-19) muestra que, en las descargas no disruptivas y fases no disruptivas

de una descarga disruptiva, los vectores de características se distribuyen en un grupo compacto. Por el contrario, en la fase disruptiva de una descarga estos vectores están lejos del grupo original. La Figura 4-19 muestra la representación de estos vectores para el caso de dos vectores de características bidimensionales.

El nivel 4 de la transformación Wavelet se aplica a la señal LM muestreada a 1 kHz en ventanas de 32 muestras actualizadas cada 2 ms. (a) Las fases disruptivas presentan valores atípicos con respecto al clúster compacto. (b) Durante las fases seguras de una descarga, los vectores se distribuyen en un grupo compacto con covarianza positiva. Debido a la covarianza entre los miembros del clúster, los valores atípicos se pueden detectar mejor utilizando la distancia de Mahalanobis.



**Figura 4-19:** Representación de los dos coeficientes de aproximación de la transformación Haar Wavelet para la descarga disruptiva (a) y no disruptiva (b) como vector de característica en un espacio bidimensional

#### 4.4.1.2. Distancia de Mahalanobis y criterio de anomalía

La distancia euclídea implica disparos de alarmas demasiado tarde ya que este tipo de distancia no tiene en cuenta ningún patrón de covarianza [31]. Como puede verse en la Figura 4-20, se puede observar una evidente covarianza positiva presente entre los puntos característicos del grupo, por lo que se elige el método de distancia Mahalanobis siguiendo la Ec. 4-9 para medir la distancia de un punto con respecto al centroide del grupo.

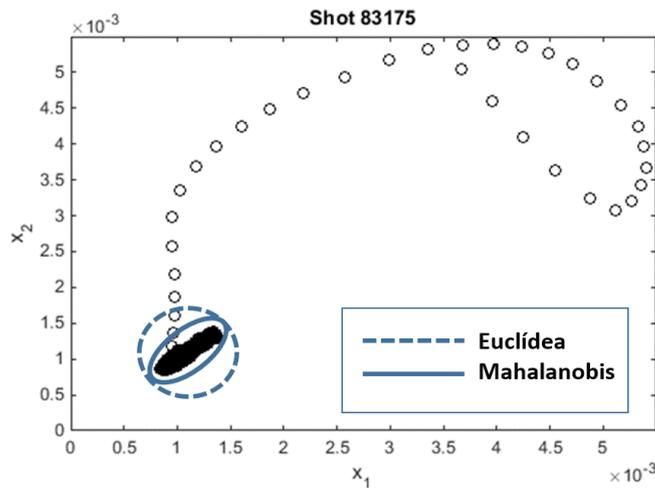


Figura 4-20: Ejemplo de distancias Euclídea y Mahalanobis para el disparo 83175 de JET

$$D_{ij}^2 = (\mathbf{X}_i - \mathbf{X}_j)^T \Sigma^{-1} (\mathbf{X}_i - \mathbf{X}_j) \quad \text{Ec. 4-9}$$

Finalmente, se calcula un criterio de anomalía usando medidas estadísticas de la distancia de Mahalanobis durante la descarga, en este caso utilizamos la desviación estándar y la media. En la Ec. 4-10 puede verse la definición matemática de este criterio de anomalía.

$$\left| \frac{D_{Mahalanobis}(t_p) - \mu(D_{Mahalanobis}(t \leq t_p))}{\sigma(D_{Mahalanobis}(t \leq t_p))} \right| \geq K \quad \text{Ec. 4-10}$$

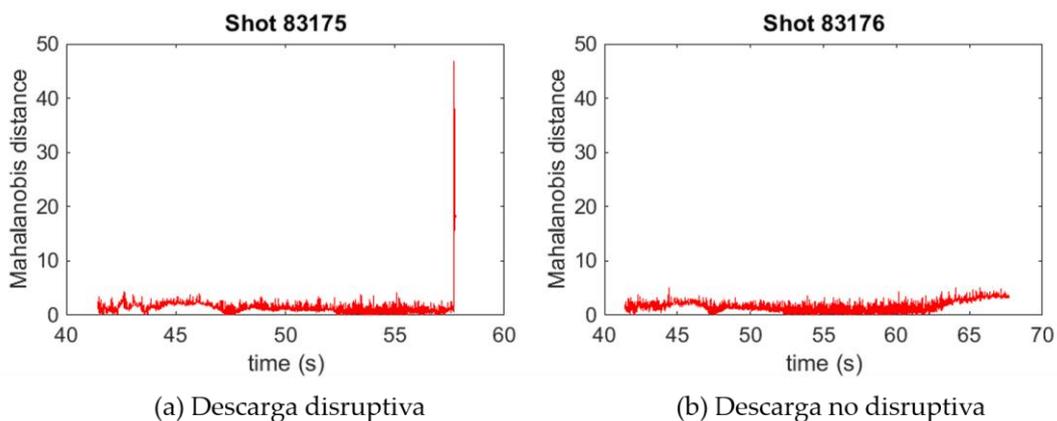


Figura 4-21: Ejemplo de distancias de Mahalanobis para cargas disruptivas y no disruptivas. En el caso de la descarga disruptiva, las distancias de Mahalanobis se disparan momentos antes de que se produzca la disrupción

La alarma de interrupción se activará cuando el criterio de anomalía supere un cierto umbral  $K$ . Un análisis empírico sobre todas las descargas de JET asociadas a las campañas ITER-ILW muestran buenos resultados de detección cuando el umbral  $K = 10$  para todas las descargas.

En la Figura 4-21 se tienen ejemplos de distancias de Mahalanobis para cargas disruptivas y no disruptivas.

#### 4.4.2. El test de martingala como criterio de anomalía

Una de las posibles debilidades de SPAD es la que tiene que ver con el valor de  $K$ , ya que dicho valor se basa en un mero criterio empírico sin una sólida justificación matemática. Este hecho hace que dependiendo del dispositivo nuclear el valor de  $K$  sea distinto. Un posible sustituto del criterio de anomalía descrito en la sección 4.4.1.2 podría ser el TM.

##### 4.4.2.1. Pruebas realizadas y resultados

Se han realizado varias baterías de prueba del TM sobre 200 descargas disruptivas de las campañas C28-C30. Las pruebas han consistido en generar diversos vectores de características de la distancia de Mahalanobis de las Wavelets de tipo Haar de la señal LM. En concreto se han realizado sendas pruebas generando vectores de componentes de detalle y aproximación del nivel 1 al 4. Para cada uno de estos vectores se ha generado un vector de distancias que será el vector de características que finalmente sea el input del TM. Como distancia se ha utilizado la de Mahalanobis, la misma que se utilizaba en SPAD. Adicionalmente se ha dejado la ventana de tiempo a 32 ms y la ventana deslizante a 2 ms como en SPAD, otros valores han sido probados sin obtener resultados mejores. En la Tabla 4-11, pueden verse alguno de los resultados de lo anteriormente comentado.

**Tabla 4-11:** Resultado detección de interrupciones en curva de salida de SPAD

$\varepsilon$	$\lambda$	Detección válida	Detección tardía	No detección
0,90	25	61,50%	7%	31,50%
	50	60,50%	9,50%	30,00%
	100	58,50%	9,50%	32,00%
0,95	25	61,00%	8,00%	31,00%
	50	60,00%	7,50%	32,50%
	100	58,50%	9,50%	32,00%
0,98	25	53,00%	14,50%	32,50%
	50	54,00%	11,00%	35,00%
	100	52,00%	13,50%	34,50%

Se ha considerado al igual que en [31] que es necesario detectar la disrupción 10 ms antes de que esta se produzca y que las detecciones anteriores a 1.5 s son prematuras. Es decir, no se corresponden a fenómenos físicos que predigan una disrupción. En la Tabla 4-11 se incluyen no detecciones y detecciones prematuras en la misma columna. En general se concluye:

- El número de falsas alarmas es muy alto y variable por lo que no se puede desarrollar soluciones como la de disparar alarmas solo si se produce un número determinado de cambios. Este hecho por si solo inhabilita al TM como criterio de anomalía en SPAD.
- El número de alarmas disparadas dentro del rango válido es bajo.
- El TM no es lo suficiente rápido como para disparar una alarma dentro del rango válido.

# 5. CONCLUSIONES Y LÍNEAS FUTURAS

---

*“La vida es el arte de sacar conclusiones suficientes a partir de datos insuficientes.”*

*Samuel Butler (1612-1680)*

## 5.1. Conclusiones

En este trabajo se ha descrito y usado un test basado en martingalas y  $p$ -valores conformales para la detección de eventos en plasmas termonucleares. En este caso se han utilizado descargas provenientes de TJ-II (Tokamak de la Junta II) y JET (Joint European Torus) para la identificación de cambios en la emisividad de plasmas y predicción de disrupciones. Adicionalmente se han utilizado imágenes de las cámaras de alta velocidad de JET para la detección de cambios en forma de radiación en el visible y se ha comparado su rendimiento con UMEL (Universal Multi-Event Locator).

Las conclusiones que pueden extraerse del uso que se ha hecho del TM (Test de Martingala) para la detección de eventos en plasmas termonucleares son las siguientes:

1. El test detecta cambios en perfiles de emisividad como pueden ser las de bolometría del TJ-II.
2. El test se ha utilizado para la detección de disrupciones en tiempo real. En este caso se ha utilizado conjuntamente con la salida de SPAD (Single signal Predictor based on Anomaly Detection) y se ha utilizado TM para detectar el momento en el que se produce dicha disrupción. El test no es lo suficientemente rápido para la detección de la disrupción. Esto es consecuencia de que los precursores del fenómeno disruptivo ocurren poco tiempo antes de que se produzca dicha disrupción.

Adicionalmente se han realizado pruebas intentando detectar el cambio mediante umbrales constantes de los  $p$ -valores conformales definidos en Ec. 3-10, en lugar de martingalas. Los resultados han mejorado, pero siguen siendo peores que los de SPAD con el valor de  $k=10$ , con el inconveniente que se siguen generando muchas falsas alarmas.

3. Para el caso de detección de cambios en imágenes de video, el método es significativamente mejor que UMEL en cuanto a eficiencia computacional.

Como ejemplo tenemos que el tratamiento del video kl8\_69331, que contiene 1.839 imágenes. TM necesita 3,797 minutos para completar el proceso frente a los 5,59 días que necesita UMEL. Además, la detección de eventos es más fina y fácil de calibrar que para el caso de UMEL.

4. El TM se vuelve muy pesado cuando no se detecta ningún cambio en un periodo largo de tiempo. Esto es debido al hecho de que el algoritmo debe comparar una determinada medida contra todos los puntos anteriores en los que no se han detectado un cambio. Este hecho haría necesario incluir un *factor de olvido* en aplicaciones reales en tiempo real que permita mejorar su eficiencia.
5. El TM detecta eventos independientemente de la naturaleza física del mismo por lo que la detección de eventos específicos, exige desarrollar arquitecturas algorítmicas de varias piezas. Por ejemplo, una de estas piezas sería el TM y otros módulos posteriores se dedicarían a discernir si el cambio detectado es el buscado o no. Un ejemplo de esto puede encontrarse en [146] (Figura 5-1).

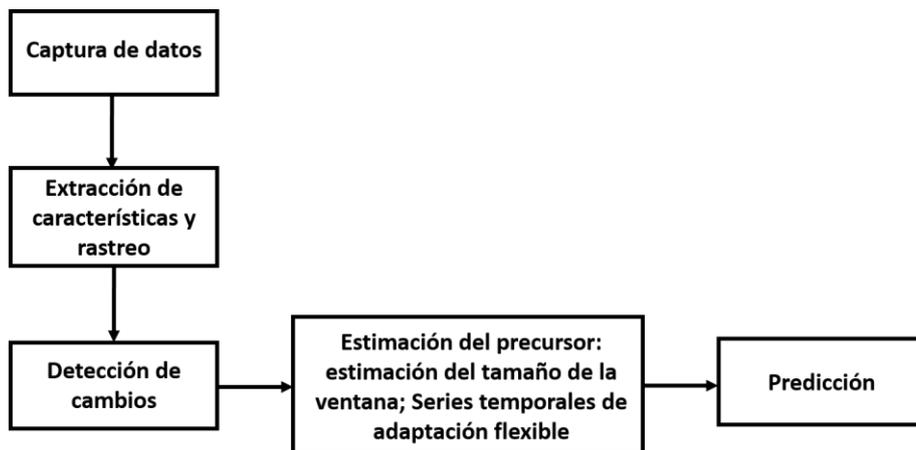


Figura 5-1: Arquitectura para la detección de estados críticos en sistemas físicos complejos [146]

## 5.2. Líneas futuras

Las futuras centrales eléctricas de fusión tendrán la necesidad de controlar cualquier tipo de perturbación del plasma para mantenerlo dentro de los parámetros de operación. Para ello, será esencial el desarrollo de algoritmos automáticos para reconocer posibles eventos relevantes (ER). Cualquier tipo de perturbación en la evolución del plasma se identificará como un ER. De esta manera, se pueden identificar eventos desconocidos y se puede analizar la tasa de repetición en diferentes escenarios del plasma. Todos los eventos deben etiquetarse y analizarse para poner en práctica contramedidas que eviten el

desarrollo de interrupciones en la operación. Por supuesto, el etiquetado de eventos desconocidos requiere una significación estadística en sus tasas de repetición.

El reconocimiento de eventos en tiempo real será crucial en ITER (International Thermonuclear Experimental Reactor). Este dispositivo no está centrado en la investigación básica sobre la física del plasma. La motivación de ITER es producir plasmas de alto rendimiento para acercar la operación a los regímenes de reactores tanto como sea posible. Se debe tener en cuenta que las descargas de ITER durarán 30 minutos y es necesario evitar el apagado de la descarga ante un mínimo de síntomas de comportamiento fuera de lo normal.

Es por ello por lo que se quiere lanzar un proyecto llamado ANOMALY-ID, cuyo objetivo es el análisis de las bases de datos de dispositivos de fusión actuales para buscar, de forma automática, cualquier tipo de ER que se muestren en las señales del plasma. Una vez que las ER están identificadas en las señales, los expertos pueden analizarlas con un doble objetivo:

1. Si el ER puede asociarse con un comportamiento físico conocido del plasma, el objetivo será avanzar en el conocimiento de la naturaleza del plasma.
2. Si el ER no corresponde a un comportamiento físico conocido, el objetivo será tratar de determinar las posibles consecuencias en el plasma y poner en funcionamiento acciones específicas de elusión o mitigación en el sistema de control (SC) del dispositivo. El dispositivo más relevante para abordar estos estudios es JET, ya que en la actualidad es el dispositivo más parecido a ITER.

Este proyecto desarrollará varios métodos de aprendizaje automático para el reconocimiento automático y el etiquetado de ER que generalmente ocurren de manera aleatoria durante la producción de descargas. Se utilizarán diferentes enfoques para el reconocimiento diferido de señales dentro de bases de datos masivas. Como se mencionó anteriormente, las señales pueden ser series de tiempo/amplitud, evolución de datos de perfiles y video-películas. En particular, se utilizará la base de datos JET (en la actualidad, tiene más de 1 TByte de datos). Una vez que los ER se ubican en varias descargas, se llevará a cabo una clasificación no supervisada de los ER. El objetivo es agrupar eventos similares y etiquetarlos. Una vez que se hayan agrupado los eventos, se desarrollarán clasificadores supervisados para asignar los eventos de nuevas descargas a uno de los grupos existentes.

Es importante mencionar que las etiquetas en el proceso de clasificación no supervisada pueden ser etiquetas con conexión desconocida a procesos físicos particulares. No obstante, en algunos casos, será posible identificar un grupo con un evento bien conocido. Sin embargo, otras etiquetas pueden permanecer sin una identificación directa sobre el mecanismo físico del evento. El objetivo importante en este caso es implementar algunas medidas correctivas en el SC para evitar el desarrollo de inestabilidades y, en particular, de interrupciones. La acción correctiva más simple podría ser la terminación ordenada de la descarga.

Para facilitar el análisis de señales en diferido, se desarrollará un entorno de software interactivo que se denominará ANOMALY-ID. Esta herramienta será un editor de flujos de datos para programar de forma gráfica las necesidades de procesamiento de datos.

El procesamiento de datos de las bases de datos de fusión actuales es diferido (off-line). Sin embargo, este proyecto también tendrá dos componentes importantes para desarrollar en condiciones de tiempo real y que se detalla a continuación:

1. La implementación en tiempo real para reconocer ER.
2. La clasificación supervisada de eventos en una de las clases determinadas de forma no supervisada por los diferentes clasificadores desarrollados en ANOMALY-ID.

El reconocimiento diferido de los ER requiere el desarrollo de detectores de anomalías para encontrar cambios significativos en la evolución temporal de las señales. De esta manera, las detecciones de anomalías permiten localizar ER cuando se modifican los parámetros morfológicos de las señales. El cambio más simple puede aparecer en forma de una variación abrupta en la amplitud de la señal. Sin embargo, una simple variación en una señal puede no significar nada. Un patrón correspondiente a un ER puede requerir cambios simultáneos en varias señales. Este tipo de patrón que requiere que se identifiquen diferentes señales se llamará *patrón de señal múltiple* (PSM) en ANOMALY-ID. Como ejemplo, es posible pensar en la aparición de un ELM (Edge Localized Mode) en el plasma. Se reconoce un ELM cuando se producen cambios repentinos de forma simultánea en tres señales [147]: Emisión  $D_\alpha$  (pico fuerte), energía diamagnética almacenada (decaimiento rápido) y densidad de línea de electrones integrada en la línea a través del pedestal de plasma (disminución rápida de la amplitud). Por lo tanto, la variación específica de amplitud en una de las señales individuales no revela por sí misma la presencia de un ELM.

Tal y como se vio en la sección 3.15 el TM puede reconocer los cambios en la distribución de datos sin la necesidad de identificar tipos de distribución. En otras

palabras, el TM prueba que las muestras son independientes y están distribuidas de manera idéntica (i.i.d). Cuando esto se viola, se detecta una anomalía. Es importante mencionar que este TM puede procesar flujos de datos simultáneamente con cualquier número de señales. Por lo tanto, este test garantiza la ubicación de los PSM.

Sin embargo, se debe tener en cuenta que la identificación de los momentos en que cambian las distribuciones de datos (es decir, la anomalía) no es suficiente para los fines de ANOMALY-ID. ANOMALY-ID necesita conocer no solo la localización temporal de la anomalía sino también los patrones morfológicos de las señales alrededor de ella (digamos un intervalo de tiempo de anchura  $t_s$ ). Esto es una consecuencia del hecho de que los diagnósticos de fusión producen patrones similares para comportamientos de plasma similares y uno de los objetivos de ANOMALY-ID es el etiquetado de los patrones que representan los ER (es decir, los PSM).

Cabe recordar que el TM no proporciona directamente los valores de  $t_s$ . Sin embargo, los posibles valores podrían obtenerse analizando la forma en que aumenta la martingala. Se pretende además implementar las diferentes martingalas descritas en la sección 3.14.5.

Por lo general, el desarrollo y las pruebas requerirán entornos de alto nivel como MATLAB. Estos entornos permiten un desarrollo ágil y rápido, que se beneficia de numerosas herramientas avanzadas de computación matemática. Sin embargo, estos tipos de entornos no están diseñados para ser utilizados en sistemas en tiempo real, y su rendimiento en términos de determinismo suele ser limitado. Por lo tanto, las implementaciones en tiempo real de los métodos propuestos anteriormente requieren la realización los siguientes pasos secuenciales:

1. La transformación de las implementaciones de alto nivel, generalmente desarrolladas en MATLAB (que consumen una gran cantidad de recursos de memoria y tiempo de computación), en las más eficientes que utilizan el hardware disponible de manera óptima y se basan en elementos que aceleran el proceso de cálculo. La propuesta de ANOMALY-ID es utilizar arquitecturas heterogéneas que incluyan dispositivos como GPU (Graphics Processing Unit) y FPGA (Field Programmable Gate Array) para acelerar el rendimiento requerido de las operaciones informáticas. Como el objetivo es poder ejecutar los algoritmos en tiempo real, un enfoque óptimo es utilizar herramientas más cercanas al hardware y basadas en el uso de C++ como lenguaje de programación. Enfoques como SYCL y OpenCL (Open Computing Language) simplifican el proceso de

desarrollo [148], [149]. El principal inconveniente de estas herramientas es que son muy novedosas, difíciles de usar y aplicar. Por lo tanto, este primer paso secuencial permite obtener algoritmos que se ejecutan en computadoras de escritorio (o estaciones de trabajo) con algún elemento de procesamiento adicional, generalmente una GPU, dependiendo de los algoritmos que se ejecuten.

2. El siguiente paso secuencial es refinar la solución obtenida en el paso anterior aplicando una arquitectura específica del sistema de control e instrumentación (SC&I), como la definida por ITER-CODAC (ITER - Control, Data Access and Communication). Esta arquitectura es actualmente la referencia para SC&I en diferentes dispositivos en la comunidad de fusión (KSTAR<sup>10</sup>, MAST-U<sup>11</sup> y W7X<sup>12</sup>). En ANOMALY-ID, se utilizará el modelo de ejecución de aplicaciones en tiempo real desarrollado por ITER. Este modelo se conoce como *Real Time Framework*, y los mecanismos de interfaz con dispositivos de comunicación y redes se basan en el modelo de *soporte de dispositivo nominal* [150], [151]. ANOMALY-ID implementará un ejemplo utilizando un controlador ITER rápido, que se basa en el estándar MTCA (Micro Telecommunications Computing Architecture), para demostrar que es posible realizar la detección de anomalías en tiempo real. Se utilizarán las señales de la base de datos JET. La adopción del estándar MTCA por ITER es un hecho sobresaliente porque otras grandes infraestructuras científicas también lo han adoptado. Por lo que, los resultados de ANOMALY-ID podrían aplicarse a otros experimentos de eScience.

---

<sup>10</sup> Korean Superconduction Tokamak Advanced Research

<sup>11</sup> Mega Amp Spherical Tokamak Upgrade

<sup>12</sup> Wendelstein 7-X

## 6. BIBLIOGRAFÍA

---

- [1] International Energy Agency, «Key world energy statistics,» 2013.
- [2] N. R. Council, *Frontiers in Massive Data Analysis*, Washington: The National Academies Press, 2013.
- [3] M. Gaillard, «CERN,» 7 July 2017. [En línea]. Available: <https://home.cern/about/updates/2017/07/cern-data-centre-passes-200-petabyte-milestone>.
- [4] K. Amunts, C. Ebell, J. Muller, M. Telefont, A. Knoll y T. Lippert, «The Human Brain Project: Creating a European Research Infrastructure to Decode the Human Brain,» *Neuron*, vol. 92, nº 3, pp. 574-581, 2016.
- [5] A. Abbott, «Neuroscience: Solving the brain,» *Nature*, nº 499, p. 272-274, July 2013.
- [6] Z. D. Stephens, S. Y. Lee, F. Faghri, R. H. Campbell, C. Zhai, M. J. Efron y G. E. Robinson, «Big Data: Astronomical or Genomical?,» *PLoS Biology*, vol. 13(7), 2015.
- [7] LSST, «LSST-Large Synoptic Survey Telescope,» 2017. [En línea]. Available: <https://www.lsst.org/>.
- [8] ESA, «<http://www.esa.int>,» [En línea]. Available: [http://www.esa.int/Our\\_Activities/Space\\_Science/Gaia/Frequently\\_Asked\\_Questions\\_about\\_Gaia](http://www.esa.int/Our_Activities/Space_Science/Gaia/Frequently_Asked_Questions_about_Gaia).
- [9] IBM, «IBM PureData System for Analytics,» [En línea]. Available: <https://www.ibm.com/ibm/puresystems/es/es/puredata-system-for-analytics.html>.
- [10] Nvidia, «Nvidia Home,» [En línea]. Available: <http://www.nvidia.es/object/gpu-computing-es.html>. [Último acceso: February 2018].

- 
- [11] MIT, «Keras Documentation,» [En línea]. Available: <https://keras.io/>.
- [12] U. d. Montréal, «theano,» [En línea]. Available: <http://www.deeplearning.net/software/theano/>.
- [13] Google, «An open source machine learning framework for everyone,» [En línea]. Available: <https://www.tensorflow.org/>.
- [14] Mittal y Sparsh, «A Survey of Techniques for Architecting and Managing Asymmetric Multicore Processors,» *ACM Comput. Surv.*, vol. 48, n° 3, pp. 45:1--45:38, 2016.
- [15] M. Balakrishnan, V. Malkhi, V. Prabhakaran, T. Wobber, M. Wei y J. D. Davis, «CORFU: A shared log design for flash clusters. Pp. 1-14 in 9th USENIX Symposium,» *USENIX Association*, 2012.
- [16] L. Golab y M. T. Özsu, «Issues in Data Stream Management,» *SIGMOD Record*, vol. 32, n° 2, 2003.
- [17] M. Armbrust, A. Fox, R. Griffith, A. D. Joseph, R. Katz, A. Konwinski, G. Lee, D. Patterson, A. Rabkin, I. Stoica y M. Zaharia, «A view of Cloud Computing,» *Communications of ACM*, vol. 53, n° 4, 2010.
- [18] Amazon, «Amazon EC2,» 2018. [En línea]. Available: <https://aws.amazon.com/es/ec2/>.
- [19] Amazon Web Services, «Instancias P2 de Amazon EC2,» 2018. [En línea]. Available: <https://aws.amazon.com/es/ec2/instance-types/p2/>.
- [20] Amazon, «Amazon S3,» 2018. [En línea]. Available: <https://aws.amazon.com/es/s3/>.
- [21] Microsoft, «Microsoft Azure,» 2018. [En línea]. Available: <https://azure.microsoft.com/es-es/>.
- [22] J. Dean y S. Ghemawat, «MapReduce: Simplified Data Processing on Large Clusters,» *Proceeding OSDI'04 Proceedings of the 6th conference on*

- Symposium on Operating Systems Design & Implementation*, vol. 6, pp. 10-10, 2004.
- [23] S. Das, Y. Sismanis, S. Beyer, R. Gemulla, P. Haas y J. McPherson, «Ricardo: Integrating R and Hadoop,» *Proceedings of the 2010 ACM SIGMOD International Conference on Management of Data. Association for Computing Machinery*, pp. 987-998, 2010.
- [24] Microsoft Research, *The Fourth Paradigm: Data-Intensive Scientific Discovery*, Redmon, 2009.
- [25] G. Bell, T. Hey y A. Szalay, «Beyond the Data Deluge,» *Science*, vol. 323, pp. 1297-1298, March 2009.
- [26] Danish Agency for Science. Technology and Innovation, «DANISH ROADMAP FOR RESEARCH INFRASTRUCTURES 2011,» 2011.
- [27] S. Griffith, «iter.org,» 6 July 2012. [En línea]. Available: <https://www.iter.org/newsline/230/1239>.
- [28] S.-S. Ho y H. Wechsler, *A martingale framework for detecting changes in data streams by testing exchangeability*, vol. 32, 2010, pp. 2113 - 2127.
- [29] J. Vega, A. Murari, S. González y JET-EFDA Contributors, «A universal support vector machines based method for automatic event location in waveforms and video-movies: Applications to massive nuclear fusion databases,» *REVIEW OF SCIENTIFIC INSTRUMENTS*, nº 81, 2010.
- [30] S. Esquembri, J. Vega, A. Murari, M. Ruiz, E. Barrera, S. Dormido-Canto, R. Felton, M. Tsalas, D. Valcarcel y Contributors JET, «Real-time implementation in JET of the SPAD disruption predictor using MARTE,» *IEEE Transactions on Nuclear Science (submitted for publication)*, 2017.
- [31] J. Vega, R. Moreno, A. Pereira, S. Dormido-Canto, A. Murari y JET Contributors, «Advanced disruption predictor based on the locked mode signal: Application to JET,» de *1st EPS Conference on Plasma Diagnostics (ECPD2015)*, Frascati - Italy, 2015.

- [32] J. Vega, A. Murari, S. Dormido-Canto, R. Moreno, A. Pereira y S. Esquembri, «Real-time anomaly detection for disruption prediction: the JET case,» *Nuclear Fusion*, Vols. %1 de %2Paper NF-101126, 2016.
- [33] J. Vega, A. Murari, S. Dormido-Canto, R. Moreno, A. Pereira, G. Rattá y JET Contributors, «Disruption precursor detection: Combining the time and frequency domains,» de *26th Symposium on Fusion Engineering (SOFE 2015)*, Austin (TX) - USA, 2015.
- [34] A. R. Bell, *Laser Produced Plasmas; Plasma Physics: An Introductory Course*, Cambridge: Cambridge University Press, 1993.
- [35] S. H. Glenzer, B. J. MacGowan, P. Michel, N. B. Meezan, L. J. Suter, S. N. Dixit, J. L. Kline, G. A. Kyrala, D. K. Bradley, D. A. Callahan, E. L. Dewald, L. Divol, E. Dzenitis, M. J. Edwards, A. V. Hamza, C. A. Haynam, D. E. Hinkel, D. H. Kalantar, J. D. Kilkenny, O. L. Landen, J. D. Lindl, S. LePape, J. D. Moody, A. Nikroo, T. Parham, M. B. Schneider, R. J. Town, P. Wegner, K. Widmann, P. Whitman, B. F. Young, B. Van Woterghem, L. J. Atherton y E. I. Moses, «Symmetric Inertial Confinement Fusion Implosions at Ultra-High Laser Energies,» *Science*, vol. 327, nº 579, pp. 1228-1231, 2010.
- [36] R. Dendy, *Plasma Physics: An Introductory Course*, Cambridge: Cambridge University Press, 1995.
- [37] J. Shefflied, «The physics of magnetic fusion-reactors,» *Rev. Mod. Phys*, nº 66, p. 1015, 1994.
- [38] P. Magaud, G. Marbach y I. Cook, «Nuclear Fusion Reactors,» *Encyclopedia of Energy*, vol. 4, pp. 365-381, 2004.
- [39] L. Spitzer, «The stellarator concept,» *Physics of Fluids*, vol. 1, p. 253, 1958.
- [40] I. Y. Tamm y A. Sakharov, «Theory of a magnetic thermonuclear reactor,» *Plasma physics and the problems of controlled thermonuclear reactions*, vol. 1, 1961.

- 
- [41] R. Moreno Salinas, PhD Thesis: Advanced techniques of disruption prediction, application to JET and extrapolation to ITER, 2015.
- [42] F. C. Schuller, «Disruption in Tokamaks,» *Plasma Phys. Control. Fusion*, vol. 37, pp. 135-62, 1995.
- [43] ITER Physics Expert Group on Disruptions, «Chapter 3: MHD stability, operational limits and disruptions,» *Nuclear Fusion*, vol. 12, 1999.
- [44] E. P. Gorbunov y K. A. Razumova, «Effect of a strong magnetic field on the magnetohydrodynamic stability of a plasma and the confinement of charged particles in the tokamak machine,» *Journal of Nuclear Energy. Part C, Plasma Physics, Accelerators, Thermonuclear Research*, vol. 6(5), p. 515, 1964.
- [45] A. H. Boozer, «Theory of tokamak disruption,» *Physics of plasmas*, nº 19, 2012.
- [46] B. Cannas, P. C. de Vries, A. Fanni, A. Murari, A. Pau, G. Sias y and JET Contributors, «Automatic disruption classification in JET with the ITER-like wall,» *Plasma Physics and Controlled Fusion*, nº 57, 2015.
- [47] S. Hugill y et al., *Nuclear Fusion*, nº 17, p. 1382, 1977.
- [48] M. Murakami, J. Callen y L. Berry, «Some Observations on Maximum densities in Tokamak Experiments,» *Nuclear Fusion*, nº 16, p. 347, 1976.
- [49] P. H. Rutherford, «Nonlinear growth of the tearing mode,» *Physics of Fluids (1958-1988)*, vol. 16(11), pp. 1903-1908, 1973.
- [50] J. A. Wesson, A. Sykes y M. F. Turner, «Tokamak Disruptions,» de *Plasma Physics and Controlled Fusion Research*, London, 1985.
- [51] S. Yoshikawa, «Design of a helical-axis stellarator,» *Nuclear fusion*, nº 23, p. 667, 1983.
- [52] J. H. Harris y et al., «A flexible heliac configuration,» *Nuclear Fusion*, nº 25,

- p. 623, 1985.
- [53] T. C. Hender, «Studies of a flexible heliac configuration,» *Fusion Technology*, nº 13, p. 521, 1988.
- [54] C. Alejaldre, «TJ-II project: A flexible heliac stellarator,» *Fusion Technology*, p. 131, 1990.
- [55] C. Alejaldre y et al., «First plasma in the TJ-II flexible heliac,» *plasma physics and controlled fusion*, vol. 41, nº 3A, 1999.
- [56] A. Fernández y et al., «Quasioptical transmission lines for ECRH at TJ-II stellarator,» *International Journal of Infrared and Millimeter Waves*, vol. 21, nº 12, p. 1945–1957, 2000.
- [57] JET, «<http://www.jet.efda.org/>,» [En línea].
- [58] Keen, B. E. Keen y P. Kupschus, «JET Joint Undertaking: Progress Report 1983,» 1984.
- [59] R.-H. Rebut, «The JET preliminary tritium experiment,» *Plasma Physics and Controlled Fusion*, vol. 34, nº 13, 1992.
- [60] M. Keilhacker y et al., «High fusion performance from deuterium-tritium plasmas in JET,» *Nuclear Fusion*, vol. 39, nº 2, pp. 209 - 234, February 1999.
- [61] J. Paméla, G. F. Matthews, V. Phillips, R. Kamendje y JET-EFDA Contributors, «An ITER-like wall for JET,» *Journal of Nuclear Materials*, Vols. %1 de %2363-365, pp. 1-11, 2007.
- [62] J. Flanagan, M. Sertoli, M. Bacharis, G. Matthews, P. C. de Vries, A. Widdowson, I. Coffey, G. Arnoux, B. Sieglin, S. Brezinsek, J. Coenen, S. Marsen, T. Craciunescu, A. Murari, D. Harting, A. Cackett, E. Hodille y JET-EFDA Contributors, «Characterising dust in JET with the new ITER-like wall,» *Plasma Physics and Controlled Fusion*, nº 57, 2015.
- [63] F. Romanelli y JET EFDA Contributors, «Overview of the JET results with the ITER-like wall,» *Nuclear Fusion*, vol. 53, nº 10, 2013.

- [64] G. J. van Rooij, J. W. Coenen, L. Aho-Mantila, S. Brezinsek, M. Clever, R. Dux, M. Groth, K. Krieger, S. Marsen, G. F. Matthews, A. Meigs, R. Neu, S. Potzel, T. Pütterich, J. Rapp, M. F. Stamp, the ASDEX Upgrade Team y JET-EFDA Contributors, «Tungsten divertor erosion in all metal devices: Lessons from the ITER like wall of JET,» *Journal of Nuclear Materials*, vol. 438, pp. S42-S47, 2013.
- [65] M. Lehnen, G. Arnoux, S. Brezinsek, J. Flanagan, S. N. Gerasimov, N. Hartmann, T. C. Hender, A. Huber, S. Jachmich y V. Kiptily, «Impact and mitigation of disruptions with the ITER-like wall in JET,» vol. 53, n° 9, 2013.
- [66] ITER, «ITER - What is ITER?,» 2018. [En línea]. Available: <https://www.iter.org/proj/inafewlines>.
- [67] R. Arnoux, «ITER news & media,» May 2014. [En línea]. Available: <https://www.iter.org/mag/3/22>.
- [68] J. Sánchez, E. Ascasibar, P. Acedo y S. Sudo, «Diagnostic system for the TJ-II flexible heliac,» *Japan Society of Plasma Science and Nuclear Fusion Research*, 1998.
- [69] L. J. Latecki, A. Lazarevic y D. Pokrajac, *Outlier Detection with Kernel Density Function*, Cologne, 2008, pp. 1-8.
- [70] V. Chandola, A. Barnejee y V. Kumar, *Anomaly detection: A survey*, vol. 41(3), 2009.
- [71] J. Roy, *Anomaly detection in the maritime domain*, vol. 6945, Orlando, 2008.
- [72] V. Barnett y T. Lewis, *Outliers in Statistical Data*, third edition ed., John Wiley and Sons, Inc., 1994.
- [73] D. Hawkins, *Identification of Outliers*, London: Chapman and Hall, 1980.
- [74] J. Tang, Z. Chen, A. W. Fu y D. W. Cheung, «Capabilities of outlier detection schemes in large datasets, framework and methodologies,»

- Knowledge and Information Systems*, vol. 11, n° 1, pp. 45 - 84, 2006.
- [75] J. Addison, S. Wermter y J. MacIntyre, «Effectiveness of feature extraction in neural network architectures for novelty detection,» *Proceedings of the 9th International Conference on Artificial Neural Networks*, vol. 2, pp. 976 - 981, 1999.
- [76] L. Ertoz, E. Eilertson, A. Lazarevic, P. N. Tan, V. Kumar, J. Srivastava y P. Dokas, «MINDS - Minnesota Intrusion Detection System,» *Data Mining - Next Generation Challenges and Future Directions*, 2004.
- [77] B. Abraham y A. Chuang, «Outlier detection and time series modeling,» *Technometrics*, vol. 31, n° 2, pp. 241 - 248, 1989.
- [78] B. Abraham y G. Box, «Bayesian analysis of some outlier problems in time series,» *Biometrika*, vol. 66, n° 2, pp. 229 - 236, 1979.
- [79] J. Zhang, «Advancements of Outlier Detection: A Survey,» *ICST Transactions on Scalable Information Systems*, February 2013.
- [80] J. Lee, J. Han y X. Li, «Trajectory Outlier Detection: A Partition-and-Detect Framework,» *ICDE'08*, pp. 140-149, 2008.
- [81] E. M. Knorr, R. T. Ng y V. Tucakov, «Distance-Based Outliers: Algorithms and Applications,» *VLDB Journal*, vol. 8, n° 3 - 4, pp. 237 - 253, 2000.
- [82] J. Sun, H. Qu, D. Chakrabarti y C. Faloutsos, «Neighborhood Formation and Anomaly Detection in Bipartite Graphs,» *ICDM'05*, pp. 418 - 425, 2005.
- [83] J. Sun, H. Qu, D. Chakrabarti y C. Faloutsos, «Relevance search and anomaly detection in bipartite graphs,» *SIGKDD Explorations*, vol. 7, n° 2, pp. 48 - 55, 2005.
- [84] E. Eskin, «Anomaly detection over noisy data using learned probability distributions,» *Proceedings of the Seventeenth International Conference on Machine Learning (ICML)*, 2000.

- [85] M. Desforge, P. Jacob y J. Cooper, «Applications of probability density estimation to the detection of abnormal conditions in engineering,» *Proceedings of Institute of Mechanical Engineers*, vol. 212, pp. 687-703, 1998.
- [86] P. S. Horn, L. Feng, Y. Li y A. J. Pesce, «Effect of outliers and nonhealthy individuals on reference interval estimation,» *Clinical Chemistry*, vol. 47, n° 12, pp. 2137 - 2145, 2001.
- [87] J. Laurikkala, M. Juhola y E. Kentala, «Informal identification of outliers in medical data,» *Fifth International Workshop on Intelligent Data Analysis in Medicine and Pharmacology*, pp. 20 - 24, 2000.
- [88] S. Guttormsson, R. M. II y M. El-Sharkawi, «Elliptical novelty grouping for on-line short-turn detection of excited running rotors,» *IEEE Transactions on Energy Conversion*, vol. 14, n° 1, 1999.
- [89] C. C. Aggarwal, «On Abnormality Detection in Spuriously Populated Data Streams,» *SIAM International Conference on Data Mining (SDM'05)*, 2005.
- [90] X. Li y J. Han, «Mining Approximate Top-K Subspace Anomalies in Multi-Dimensional Time-Series Data,» *VLDB*, pp. 447-458, 2007.
- [91] P. Helman y J. Bhangoo, «A statistically based system for prioritizing information exploration under uncertainty,» *IEEE International Conference on Systems, Man, and Cybernetics*, vol. 27, pp. 449-466, 1997.
- [92] D. Dasgupta y F. Nino, «A comparison of negative and positive selection algorithms in novel pattern detection,» *the IEEE International Conference on Systems, Man, and Cybernetics*, vol. 1, pp. 125-130 , 2000.
- [93] E. Parzen, «On the estimation of a probability density function and mode,» *Annals of Mathematical Statistics*, n° 33, pp. 1065-1076, 1962.
- [94] T. Palpanas, D. Papadopoulos, V. Kalogeraki y D. Gunopoulos, «Distributed deviation detection in sensor networks,» *SIGMOD Record*, vol. 32, n° 4, pp. 77-82, 2003.

- [95] J. Branch, B. Szymanski, B. Giannella y H. Ran Wolff Kargupta, «n-Network Outlier Detection in Wireless Sensor Networks,» *Proc. of 26th IEEE International Conference on Distributed Computing Systems (ICDCS)*, 2006.
- [96] E. M. Knorr y R. T. Ng, «Algorithms for Mining Distance-based Outliers in Large Dataset,» *Proc. of 24th International Conference on Very Large Data Bases (VLDB'98)*, pp. 392-403, 1998.
- [97] W. Wang, J. Zhang y H. Wang, «Grid-ODF: Detecting Outliers Effectively and Efficiently in Large Multidimensional,» de *Proc. of 2005 International Conference on Computational Intelligence and Security (CIS'05)*, Xi'an, China, 2005.
- [98] M. Breuning, H.-P. Kriegel, R. Ng y J. Sander, «LOF: Identifying Density-Based Local Outliers,» de *Proc. of 2000 ACM SIGMOD International Conference on Management of Data (SIGMOD'00)*, Dallas, Texas, 2000.
- [99] J. Tang, Z. Chen, A. Fu y D. W. Cheung, «Enhancing Effectiveness of Outlier Detections for Low Density Patterns,» de *Proc. of 6th Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD'02)*, Taipei, Taiwan, 2002.
- [100] A. K. Jain y R. C. Dubes, *Algorithms for Clustering Data*, Prentice-Hall, Inc, 1988.
- [101] S. Basu, M. Bilenko y R. J. Mooney, «A probabilistic framework for semi-supervised clustering,» de *Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining*, New York, NY, USA, 2004.
- [102] L. Kaufman y P. J. Rousseeuw, *Finding Groups in Data: an Introduction to Cluster Analysis*, John Wiley&Sons, 1990.
- [103] J. MacQueen, «Some methods for classification and analysis of multivariate observations,» de *Proc. of 5th Berkeley Symp. Math. Statist, Prob*, 1967.

- [104] R. Ng y J. Han, «Efficient and Effective Clustering Methods for Spatial Data Mining,» de *proceedings of the 20th VLDB Conference*, 1994.
- [105] C. T. Zahn, «Graph-theoretical Methods for Detecting and Describing Gestalt Clusters,» *IEEE Transaction on computing*, Vols. C-20, pp. 68-86, 1971.
- [106] S. Guha, R. Rastogi y K. Shim, «CURE: An Efficient Clustering Algorithm for Large Databases,» *Proceedings of the 1998 ACM SIGMOD International Conference on Management of Data (SIGMOD'98)*, 1998.
- [107] G. Karypis, E.-H. Han y V. Kumar, «CHAMELEON: A Hierarchical Clustering Algorithm Using Dynamic Modeling,» *IEEE Computer*, nº 32, pp. 68-75, 1999.
- [108] M. Ester, H.-P. Kriegel, J. Sander y X. Xu, «A Density-based Algorithm for Discovering Clusters in Large Spatial Databases with Noise,» de *2nd International Conference on Knowledge Discovery and Data Mining (KDD'96)*, Portland, Oregon, USA, 1996.
- [109] A. Hinneburg y D. A. Keim, «An Efficient Approach to Cluster in Large Multimedia Databases with Noise,» de *KDD'98*, 1998.
- [110] W. Wang, J. Yang y R. Muntz, «STING: A Statistical Information Grid Approach to Spatial Data Mining,» de *23rd VLDB Conference*, Athens, Greek, 1997.
- [111] G. Sheikholeslami, S. Chatterjee y A. Zhang, «WaveCluster: A Wavelet based Clustering Approach for Spatial Data in Very Large Database,» vol. 8, nº 3-4, pp. 289-304, 1999.
- [112] J. Zhang, W. Hsu y M. L. Lee, «Clustering in Dynamic Spatial Databases,» *Journal of Intelligent Information Systems (JIIS)*, vol. 24, nº 1, pp. 5-27, 2005.
- [113] C. C. Aggarwal y P. S. Yu, «Outlier Detection in High Dimensional Data,» de *2001 ACM SIGMOD International Conference on Management of Data (SIGMOD'01)*, Santa Barbara, California, USA, 2001.

- [114] C. C. Aggarwal y P. S. Yu, «An effective and efficient algorithm for high-dimensional outlier detection,» *VLDB Journal*, nº 14, pp. 211-221, 2005.
- [115] C. Zhu, H. Kitagawa y C. Faloutsos, «Example-Based Robust Outlier Detection in High Dimensional Datasets,» de *2005 IEEE International Conference on Data Management (ICDM'05)*, 2005.
- [116] C. Zhu, H. Kitagawa, S. Papadimitriou y C. Faloutsos, «OBE: Outlier by Example. PAKDD'04,» 2004.
- [117] L. Boudjeloud y F. Poulet, «Visual Interactive Evolutionary Algorithm for High Dimensional Data Clustering and Outlier Detection,» de *9th Pacific-Asia Conference on Advances in Knowledge Discovery and Data Mining (PAKDD'05)*, Hanoi, Vietnam, 2005.
- [118] K. Das y J. G. Schneider, «Detecting anomalous records in categorical datasets,» de *KDD'07*, 2007.
- [119] E. M. Knorr y R. t. Ng, «Finding Intentional Knowledge of Distance-based Outliers,» de *25th International Conference on Very Large Data Bases (VLDB'99)*, Edinburgh, Scotland, 1999.
- [120] J. Zhang y H. Wang, «Detecting Outlying Subspaces for High-dimensional Data: the New Task, Algorithms and Performance,» *Knowledge and Information Systems: An International Journal (KAIS)*, 2006.
- [121] J. Zhang, Q. Gao y H. Wang, «A Novel Method for Detecting Outlying Subspaces in High-dimensional Databases Using Genetic Algorithm,» de *IEEE International Conference on Data Mining (ICDM'06)*, Hong Kong, China, 2006.
- [122] D. Kifer, S. Ben-David y J. Gehrke, «Detecting Change in Data Streams,» de *Proceedings of the 30th VLDB Conference*, Toronto, Canada, 2004.
- [123] S.-S. Ho y H. Wechsler, «Detecting changes in unlabeled data streams using martingale,» *Proceedings of the 20th International Joint Conference on Arti*, pp. 1912 - 1917, 2007.

- [124] A. Bifet, G. Holmes, B. Pfahringer, P. Kranen, H. Kremer, T. Jansen y T. Seidl, «Moa: Massive online analysis, a framework for stream classification and clustering,» *Journal of Machine Learning Research (JMLR) Workshop and Conference Proceedings*, vol. 11, pp. 44-50, 2010.
- [125] V. Vovk, I. Nouretdinov y A. Gammerman, «Testing exchangeability on-line,» 2003.
- [126] V. N. Vapnik, *Statistical Learning Theory*, Wiley-Interscience, 1998.
- [127] V. Cherkassky y F. Mulier, *Learning from data*, New York: John Wiley & Sons, 2007, p. 380.
- [128] V. Vovk, A. Gammerman y G. Shafer, *Algorithmic Learning in a Random World*, New York: Springer-Verlag, 2005.
- [129] S. Vanderlooy y I. G. Sprinkhuisen-Kuyper, «An Overview of Algorithmic Randomness and its Application to Reliable Instance Classification,» *Technical Report MICC-IKAT*, 2006.
- [130] J. Vega, A. Murari, A. Pereira, S. González y I. Pastor, «Accurate and reliable image classification by using conformal predictors in the TJ-II Thomson scattering,» *Review of Scientific Instruments*, vol. 81(10), October 2010.
- [131] G. Shafer y V. Vladimir, «A tutorial on conformal prediction,» *Journal Machine Learning*, nº 9, pp. 371-421, June 2008.
- [132] V. N. Vapnik, *The Nature of Statistical Learning Theory*, 2nd ed., New York: Springer, 1999.
- [133] S. Theodoridis y K. Koutroumbas, de *An Introduction to Pattern Recognition: A MATLAB Approach*, 2010.
- [134] J. Hernández Orallo, M. J. Ramírez Quintana y C. Ferri Ramírez, *Introducción a la minería de datos*, Madrid: Pearson Prentice Hall, 2007.

- [135] V. Fedorova, A. Gammerman, I. Nouretdinov y V. Vovk, «Plug-in martingales for testing exchangeability on-line.» de *Proceedings of the Twenty Ninth International Conference on Machine Learning (ICML 2012)*, Edinburgh - Scotland, 2012.
- [136] W. Martinez, *Computational statistics handbook with MATLAB*, Chapman & Hall/CRC, 2001.
- [137] V. Epanechnikov, «Nonparametric estimates of a multivariate probability density.» *Theory of probability and its applications*, nº 14, pp. 153 - 158, 1969.
- [138] M. Steele, *Stochastic Calculus and Financial Applications*, Springer-Verlag, 2001.
- [139] S.-S. Ho, «22nd international conference on Machine learning.» de *Proceeding ICML '05 Proceedings of the 22nd international conference on Machine learning*, 2005.
- [140] J. Vega, S. Dormido-Canto, T. Cruz, M. Ruiz, E. Barrera, R. Castro, A. Murari y M. Ochando, «Real-time change detection in data streams with FPGAs.» *FUSION ENGINEERING AND DESIGN*, vol. 89, nº 5, pp. 644-648, May 2014.
- [141] J. Sánchez, M. Acedo, D. Alegre, A. Alonso, P. Álvarez y et al., «Overview of TJ-II experiments.» *Nuclear Fusion*, nº 51, 2011.
- [142] M. Ruiz, J. Vega, G. Arcas, G. Rattá, E. Barrera, A. Murari, J. López, R. Meléndez y and JET-EFDA Contributors, «Real Time Plasma Disruptions Detection in JET Implemented with ITMS Platform Using FPGA Based IDAQ.» *IEEE Transactions on Nuclear Science*, vol. 4, nº 58, pp. 1576-1581, 2011.
- [143] J. Paméla, F. Romanelli, M. L. Watkins, A. Lioure, G. Matthews, V. Philipps, T. Jones, A. Murari, A. Géraud, F. Crisanti, R. Kamendje y JET-EFDA Contributors, «The JET programme in support of ITER.» *Fusion Engineering and Design*, vol. 82, nº 5-14, pp. 590-602, October 2007.

- 
- [144] J. A. Alonso y et al, «Fast visible camera installation and operation in JET,» de *International Workshop on Burning Plasma Diagnostics*, Villa Monastero, Varenna, Italy, 2007.
- [145] A. Bovik, *The Essential Guide to Image Processing*, Segunda ed., Austin, Texas: Elsevier, 2009.
- [146] H. Wechsler y S.-S. Ho, «Intelligent Evidence-Based Management for Data Collection and Decision-Making Using Algorithmic Randomness and Active Learning,» *Intelligent Information Management*, vol. 3, nº 4, pp. 142-159, 2011.
- [147] J. Vega, «Intelligent methods for data retrieval in fusion databases,» *Fusion Engineering and Design*, nº 83, p. 382–386.
- [148] H. Silva, F. Pisani y E. Borin, «A Comparative Study of SYCL, OpenCL, and OpenMP,» *Proceedings - 28th IEEE International Symposium on Computer Architecture and High Performance Computing Workshops*, pp. 61-66, 2017.
- [149] Reyes-lomüller, «SYCL: Single Source C++ Accelerator Programming,» de *Conference Proceedings, Advances in Parallel Computing*, 2016.
- [150] A. Winter, «Overview of ITER Real Time Framework(RTF).,» de *CODAC Hands-on workshop o Diagnostics I&C*, Cadarache, 2018.
- [151] R. Lange, «CODAC for Plan Systems I&C – from DAQ to Data Access,» de *CODAC Hands-on workshop o Diagnostics I&C*, Cadarache, 2018.



# Anexo A – Test de martingalas

---

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
%                               Test de Martingala
%
% Un test de Martingalas para la detección de cambios en flujos
% de datos mediante un test de intercambiabilidad
%
%                               Autor: Tomás Cruz Barrios
%
% Bibliografía: Shen-Shyan Ho, Harry Wechsler: "A Martingale
% Framework for Detecting Changes in Data Streams by Testing
% Exchangeability," IEEE Transactions on Pattern Analysis and
% Machine Intelligence, Vol. 32, N° 12, December 2010
%
% Parámetros:
%   epsilon: valor entre 0 y 1.
%   lambda
%   martingale: Tipo Martingala
%       0 - Randomized Power Martingale
%       1 - Simple Mixture Martingale
%       2 - Plug-In Martingale
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

echo off;
clc;
tic;
load('seq001.mat'); %lee el conjunto de datos y crea la
variable caract

cambios = [];
epsilon=0.85;
lambda = 20;
martingale = 0; %0-RPM; 1-SMM; 2-PIM
tamano_test = size(caract, 1);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   Comienzo Algoritmo de Test de Martingala   %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
T = [];
cambios = [];
Ps = [];
M = 1;
k = 1;

for i =1:tamano_test
    if size(T, 1) < 2
```

```

    s = 0;
else
    s = strangeness_cluster(T);
end

Ps = p_valor(s);

switch martingale
    case 0 %Random Power Martingale
        M = M*rand_pow_martingale(Ps, epsilon);
    case 1 %Simple Mixture Martingale
        acum = acum*Ps;
        M = sim_mix_martingale(acum, i);
    case 2 % %Plug-in Martingale
        distpval = Ps;
        data = [-distpval(1:i-1), distpval(1:i-1), 2-distpval(1:i-1)];
        len = length(data);
        stdev = std(data);
        h = 1.06*stdev*len^(-1/5); % normal reference rule
        fhat01 = fkerg(x01, data, h);
        factor = dx*trapz(fhat01);
        fNorm = fhat01/factor;
        val = interp1(x01, fNorm, distpval(i));
        M = M*val;
end

clc;
fprintf('M = : %.3f\n', M);

if M > lambda
    fprintf('Detectado cambio en iteración: %d\n', i);
    T = [];
    M = 1;
    cambios(k) = i;
    k = k+1;
    pause;
else
    T = [T; caract(i, :)];
end

fprintf('Lambda: %d; i: %d; epsilon%d: %.3f; p-valor:
        %.3f\n', lambda, i, j, epsilon, Ps);
end

tiempo_ejecucion = toc/60;

fprintf('Tiempo de ejecución: %10.3f minutos.\n',
tiempo_ejecucion);

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
%               Randomized Power Martingale
%
%               Autor: Tomás Cruz Barrios
%
%
% Entradas:
% P: conjunto de P-valores
% epsilon: valor entre 0 y 1
%
% Salida:
% M: Valor de la martigala
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

function [M] = rand_pow_martingale (p, epsilon)
    if p == 0
        M = 1;
    else
        M = epsilon*p^(epsilon-1);
    end
end

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
%               Simple Mixture Martingale
%
%               Autor: Tomás Cruz Barrios
%
%
% Entradas:
% P: pvalor actual
% n: número de iteración
%
% Salida:
% M: Valor de la martigala
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

function [M] = sim_mix_martingale (p, n)
    if p == 0
        M = 1;
    else
        f = @(e)e.^n.*(p.^(e-1));
        M = quad(f,0,1);
    end
end

```



```
p = (contador + rand()*contador2)/(tamano);  
end
```



