



PONTIFICIA
UNIVERSIDAD
CATÓLICA DE
VALPARAÍSO



Ismael Andrés Martínez Cisternas

Clasificación de interrupciones nucleares con métodos ensamblados en dispositivo Tokamak

Informe Proyecto de Título de Ingeniero Civil Electrónico



**Escuela de Ingeniería Eléctrica
Facultad de Ingeniería**

Valparaíso, 27 de febrero de 2018



Clasificación de disrupciones nucleares con métodos ensamblados en dispositivo Tokamak

Ismael Andrés Martínez Cisternas

Informe Final para optar al título de Ingeniero Civil Electrónico,
aprobada por la comisión de la
Escuela de Ingeniería Eléctrica de la
Facultad de Ingeniería de la
Pontificia Universidad Católica de Valparaíso
conformada por

Sr. Gonzalo Alberto Farías Castro
Profesor Guía

Sr. Gabriel Enrique Hermosilla Vigneau
Segundo Revisor

Sr. Sebastián Fingerhuth Massmann
Secretario Académico

Valparaíso, 27 de febrero de 2018

Resumen

El presente informe entrega todas las bases para comprender el marco global de la fusión nuclear. Tanto su principio de funcionamiento como el por qué se está prefiriendo este tipo de energía y sus ventajas frente a otras fuentes convencionales de energía.

Se realizaron diversos enfoques para resolver el mismo problema; cómo predecir las disrupciones nucleares. Tratar un problema difícil desde distintos puntos de vista es de vital importancia para ir logrando resultados y poder realizar comparaciones con métodos antiguos. Si bien los resultados no son los esperados, en esta oportunidad se usaron señales que son de fácil procesamiento y con reglas muy sencillas para que el modelo sea de fácil comprensión.

Se utilizó el algoritmo Adaboost como clasificador y con un muy buen desempeño, fue posible obtener unas tasas de acierto bastante aceptable y teniendo pleno conocimiento de la importancia de cada una de las señales utilizadas, cumpliendo así una de las grandes premisas de este trabajo que consistió en obtener modelos explícitos en vez de simples modelos de caja negra como en el caso de los algoritmos tradicionales.

Se mezcló el algoritmo Adaboost con un clasificador en cascada propuesto por Viola-Jones para mejorar los resultados individuales de cada una de las etapas del cascada. Se pudo comprobar empíricamente que incluso los tiempos en los que se detectan las disrupciones mejoraron considerablemente y se acercan bastante a lo exigido por los dispositivos experimentales.

Cabe destacar que muchos de los métodos propuestos no generaron los resultados esperados y tuvieron que descartarse, por lo que los modelos obtenidos necesitaron una gran cantidad de tiempo de experimentación.

Palabras claves: machine learning, adaboost, clasificador, cascada, automatización.

Índice general

Introducción.....	1
1 Contextualización.....	4
1.1 Producción de energía.....	4
1.2 Disrupciones.....	5
1.3 Dispositivos de fusión nuclear.....	6
1.3.1 Stellarator.....	6
1.3.2 Tokamak.....	7
1.4 Clasificadores.....	8
1.4.1 Redes neuronales.....	9
1.4.2 Máquina de vectores soporte.....	10
1.4.3 Métodos ensamblados.....	10
1.5 Motivación.....	11
1.5.1 Sistema de caja negra.....	11
1.5.2 Sistema de caja transparente.....	12
2 Estado del Arte.....	13
2.1.1 Predictores por redes neuronales.....	13
2.1.2 Predictores por lógica difusa.....	14
2.1.3 Predictores por SVM (Máquina de vectores soporte).....	14
2.2 Adaboost.....	14
2.3 Ejemplo ilustrativo.....	15
3 Análisis temporal de señales.....	19
3.1 Señales analizadas.....	19
3.1.1 Mode Lock.....	19
3.1.2 Evolución temporal de la afluencia del Tungsteno.....	19
3.1.3 Energía diamagnética.....	19
3.1.4 Potencia de entrada y potencia radiada.....	20
3.1.5 Señales bolométricas.....	20
3.2 Acotamiento por corriente de plasma.....	20
3.3 Concepto de Warning Time (WT).....	21

3.4 Enfoque de centroides.....	23
3.4.1 Centroide descarga disruptiva	23
3.4.2 Centroide descarga safe	24
3.5 Enfoque de Peaking Factor	24
3.6 Enfoque de ventanas	27
3.6.1 Clasificador en cascada.....	28
3.6.2 Selección de datos	30
3.6.3 Ventana deslizando	30
4 Experimentos y resultados.....	31
4.1 Experimento con centroides	31
4.1.1 Centroides con señal Mode Lock	31
4.1.2 Centroides con señal Nivel de afluencia del Tungsteno	32
4.1.3 Centroides con señal Energía diamagnética.....	34
4.2 Experimento con ventanas temporales	36
4.2.1 Selección de datos disruptivos	36
4.2.2 Metodo de selección de datos safe aleatorios.....	36
4.2.3 Método de selección de datos safe centrales	37
4.2.4 Resultados obtenidos.....	38
4.2.5 Resultados obtenidos sin Mode Lock	40
Discusión y conclusiones.....	41
Bibliografía	43

Introducción

Desde que la especie humana comenzó a asentarse permanentemente en lugares, se percató que era absolutamente necesario buscar fuentes de energía. Como no existían los artefactos que hoy en día se usan para ese propósito, se inició con pequeños generadores que funcionaban con fuerzas naturales, como ríos o viento. Estos generadores solo cambiaban en parte el aspecto visual de los sectores en los que se instalaban y producían poca o nula contaminación.

Los tiempos fueron cambiando, la población fue creciendo y la demanda de energía también; fue necesario idear nuevos métodos de generación de energía. Es por eso que comenzaron a explotar los recursos naturales para aumentar la producción de energía y cubrir las demandas.

El principal problema de esto fue que los recursos naturales se han ido agotando poco a poco con los años. A modo de solución se plantea dejar de producir energía con recursos y en vez de eso hacerlo con el conocimiento. Es por eso que la fusión nuclear viene siendo la última de las opciones para generación de energía limpia y con utilización mínima de recursos naturales.

Los sensores son de vital importancia para tener conocimiento de los diferentes fenómenos naturales o artificiales. Estos permiten recolectar información necesaria que permite el estudio teórico de dichos fenómenos. Es en este momento en el que se hace necesario representar los datos recolectados, por lo general se hace por medio de señales temporales, éstas se grafican con el tiempo en el eje X y el dato en el eje Y.

De forma particular, el reactor de fusión europeo JET tiene una gran cantidad de sensores que sirven de medio de comunicación para que los científicos puedan tener una idea de lo que sucede al interior del toroide. Además los datos recopilados han servido para generar modelos predictivos y elaborar reglas que permitan clasificar la descarga como disruptiva antes de que ocurra. Un buen ejemplo de modelo predictivo es el algoritmo Adaboost.

El algoritmo Adaboost fue propuesto en 1995 por Yoav Freund y Robert Shapire como un método general para generar un clasificador fuerte proveniente de un grupo de clasificadores débiles (o hipótesis débiles) [1]. Se trata principalmente de un algoritmo iterativo en donde la cantidad de iteraciones ayuda a disminuir el error progresivamente.

De un modo simple, se trata de seleccionar el mejor y más simple clasificador después de cada iteración. Cada hipótesis seleccionada tendrá un peso asociado acorde a su capacidad de

clasificar el conjunto de entrenamiento correctamente. De forma análoga, aquellas muestras que fueron mal clasificadas también tendrán un peso asociado que permitirá encontrar hipótesis futuras cuyas reglas serán vitales para lograr un acierto en la clasificación de las siguientes iteraciones.

En el marco de la actualidad, existe un gran proyecto llamado ITER (International Thermonuclear Experimental Reactor) cuyo objetivo es determinar la viabilidad tecnológica y económica de la fusión nuclear por confinamiento magnético para la generación eléctrica. Lo anterior para justificar adecuadamente la construcción de una instalación de demostración comercial, es decir que sea rentable la generación de energía eléctrica basada en fusión nuclear [2].

Es importante señalar que la dificultad mayor en los dispositivos tipo Tokamak (como el ITER) se da cuando ocurren descargas disruptivas, esto último puede explicarse como una inestabilidad en el plasma. En consecuencia las paredes de los dispositivos se dañan y el experimento debe detenerse forzosamente. Como los costos de operación no son menos importantes, es de sumo interés idear un sistema que permita actuar con suficiente rapidez para tomar medidas, ya sea de mitigación o evitación.

En la actualidad hay sistemas de predicción de interrupciones en funcionamiento, sin embargo los modelos y algoritmos utilizados no proporcionan suficiente información para actuar a tiempo frente a descargas disruptivas. Además estos predictores funcionan bajo los conceptos de redes neuronales, lógica difusa y máquinas de vectores soporte.

Los métodos antes mencionados funcionan con la lógica de *caja negra*, esto quiere decir que no se tiene pleno conocimiento de las variables que inciden en la decisión del sistema predictor. La nueva perspectiva es conocer con suma precisión las variables que afectan en la salida del predictor, haciendo factible la manipulación manual del dispositivo Tokamak y observar en tiempo real como las variables cambian. Esto permite forzar la salida del predictor y así también forzar una descarga no disruptiva.

Tener la posibilidad de controlar correctamente y eficientemente la fusión nuclear supondría el término de la mayoría de los problemas energéticos a nivel mundial y el cambio de paradigma en el ámbito de la generación de energía. La mayoría de las personas involucradas tanto en el financiamiento como en la investigación de este tipo de generación de energía apoyan la idea de compartir ya sea la energía generada o conocimientos necesarios para construir este tipo de dispositivos.

Es por todo lo expuesto anteriormente que se propondrá una solución a los problemas globales de energía mediante una acción indirecta: Controlar la fusión nuclear. Lograr dicho objetivo puede ser un proceso muy largo y trabajoso, sin embargo se irá en busca de una solución parcial que permita tanto avanzar con los trabajos hechos anteriormente como también plantear bases sólidas que sirvan como puerta de entrada a nuevos trabajos y enfoques. A continuación se presentan justamente lo que serán los objetivos del presente trabajo, necesarios para cumplir todas las metas propuestas.

- Objetivo general: Diseñar e implementar un sistema predictivo de señales disruptivas en fusión nuclear.
- Objetivos específicos:
 - Estudiar la problemática de la disrupción en dispositivos de fusión nuclear.
 - Estudiar los enfoques actuales de pronóstico de disrupción y Ensemble Learning.
 - Diseñar algoritmos de pronósticos del tipo de disrupción y el tiempo en que ocurrirá.
 - Implementar los algoritmos diseñados y probarlos con bases de datos reales de un dispositivo de fusión nuclear.


1 Contextualización

Este capítulo describe los actuales métodos convencionales de producción de energía y sobre principios de funcionamiento de los dispositivos de fusión nuclear. También se explicarán los conceptos básicos de redes neuronales, máquinas de vectores soporte y las técnicas de aprendizaje automático; en particular sobre métodos ensamblados.

1.1 Producción de energía

En la actualidad, la producción de energía se centra en la explotación de recursos naturales. Esto quiere decir que están ocupándose recursos constantemente para satisfacer las necesidades energéticas de ciudades o comunidades. Es importante mencionar que la utilización de recursos naturales para obtener energía es una cadena de eventos contaminantes y nocivos para el planeta. Extraer dichos recursos contempla el uso de maquinaria pesada y dicha maquinaria requiere de energía para desempeñar las tareas, generalmente se obtiene del petróleo que, al incinerarse emite monóxido de carbono. Esto implica que tan solo la extracción de recursos origine potenciales focos de contaminación.

Consumo de energía primaria mundial 2015



Como se puede apreciar en la , las principales fuentes de energía corresponden a aquellas que son las más contaminantes, tanto en el impacto ambiental y geográfico como en la emisión de sustancias tóxicas y huella de carbono. Cabe destacar que las energías renovables y de bajo impacto no son de la era moderna, tan solo no se explotaron tanto porque la generación de energía era lenta y de baja explosividad.




Figura 1-1. Consumo de energía mundial año 2015 [3]

1.2 Disrupciones

Las disrupciones nucleares son eventos masivos y catastróficos que ocurren al interior de los dispositivos de fusión nuclear. Los dispositivos actuales son capaces de acumular mucha más energía cuando el plasma se está calentando [4], esto es perjudicial pues el daño provocado durante alguna falla podría ser mucho peor. Las disrupciones más comunes ocurren cuando el plasma se bloquea, vale decir, deja de girar al interior del toroide, esto ocasiona un aumento súbito de la temperatura debiendo detenerse la descarga.

Las paredes de los reactores de fusión nuclear se construyen con aleaciones bastante potentes, desde el carbón hasta el tungsteno. Ambos materiales poseen una importante capacidad de resistir las altas temperaturas, cabe mencionar que su estructura interna supone una sólida barrera protectora para todo el equipamiento tecnológico del dispositivo de fusión nuclear. Esto último es de particular interés para la gran mayoría de los reactores, pues todos los sensores son muy frágiles y excesivamente costosos. Una vez que una disrupción ocurre al interior del dispositivo, la temperatura que deben soportar las paredes es del orden de los 3000 °C [5], por lo que además de proteger el equipamiento, también se busca evitar desastres como los que ocurren en las centrales de generación energética convencionales.

El fenómeno físico que conlleva una disrupción nuclear en dispositivos de fusión nuclear es bastante complejo y no lineal, lo que ha dificultado de manera significativa el control y a su vez, el monitoreo de las descargas ocurridas al interior del reactor.

Reparar los dispositivos luego de una disrupción es excesivamente costoso y consume una cantidad enorme de tiempo, por lo que es vital lograr predecirlas. El tiempo empleado en la reparación implica que no se puedan seguir ejecutando experimentos, eso implica una pérdida importante de desarrollo científico. En la Figura 1-2 se puede apreciar el daño provocado por una disrupción. Allí puede observarse como se fundieron una gran cantidad de bloques. La construcción de los dispositivos por lo general se hace en bloques para que la reparación solo se haga en aquellas zonas dañadas.



Figura 1-2. Daño provocado por disrupción

1.3 Dispositivos de fusión nuclear

La fusión nuclear no es un proceso que se haya desarrollado hace muchos años, de hecho se lleva investigando desde los años 1950 y se formalizó como ciencia en la década del 70'. Este tipo de tecnología es tan costosa que se hizo necesaria cooperación internacional, es por eso que hay muchas instituciones que han construido dispositivos para realizar gran cantidad de experimentos. A continuación se listan aquellos tipos que son más comunes.

1.3.1 Stellarator

El dispositivo de tipo Stellarator fue inventado por Lyman Spitzer en los años 50', tras eso se fundó el Laboratorio de Física de Plasma de Princeton (PPPL por sus siglas en inglés). El dispositivo fue desarrollado en primera instancia para validar el modelo que permitiese confinar el plasma al interior de las bobinas.

Al igual que la mayoría de los dispositivos de fusión termo nuclear, el Stellarator confina el plasma caliente con campos magnéticos con el fin de lograr una fusión controlada sin que el plasma tenga la posibilidad de escapar del dispositivo y generar daños tanto en la estructura como en las instalaciones. El principal inconveniente de este tipo de dispositivos es que las componentes de campo magnético necesarias para el confinamiento son muy complejas, lo que ocasiona que las bobinas utilizadas requieran una precisión difícil de conseguir [6].

El primer modelo (llamado "Modelo A") inicio sus operaciones en 1953, cabe destacar que dicho dispositivo fue utilizado solo para realizar experimentos. Modelos más grandes fueron desarrollados, pero demostraron tener un muy mal desempeño por un problema que ocasionaba que el plasma se perdiera a una tasa mucho mayor a la calculada previamente. Sin embargo, más adelante, gracias al diseño asistido por computadora fue posible la construcción de bobinas más complejas y con esto se pudieron eliminar algunas inestabilidades que ocurrían al interior.

En la Figura 1-3 se representa en color amarillo el plasma y en azul el arreglo de bobinas para confinarlo. Puede apreciarse la complejidad de la estructura y lo preciso que debe ser la

instalación del equipo. Lo anterior demuestra la dificultad en aquellos años de conseguir la precisión mecánica que en la actualidad pareciese completamente normal.




Figura 1-3. Diseño de Stellarator, experimento Wendelstein 7-X

1.3.2 Tokamak

Los dispositivos Tokamak, al igual que la mayoría de los dispositivos de gran envergadura y vanguardistas, requiere una fuerte investigación previa. Es por eso que las investigaciones experimentales de estos dispositivos comenzaron alrededor de 1956 en Moscú, actual Rusia. Un grupo de científicos soviéticos, liderados por Lev Artsimovich dieron vida al primer Tokamak y a sus distintas versiones. Cabe destacar que fueron muchos modelos experimentales los que se llevaron a cabo, sin embargo la última versión llamada T-4 logró por primera vez una reacción termonuclear cuasi-estacionaria.

Este tipo de dispositivo también utiliza campos magnéticos para confinar el plasma en su interior, la idea principal es lograr mantener el plasma en la sección central de la estructura, de manera que se encuentren las partículas muy unidas entre si, en caso contrario el plasma se enfriaría rápidamente. La estructura general consiste, de forma muy general y muy básica, en dos grandes conjuntos de bobinas, una central y otra exterior.

Las descargas de los dispositivos Tokamak son de especial interés en este trabajo, pues los experimentos realizados han sido con datos reales del JET (Joint European Torus). Dicho dispositivo comenzó a operar en el año 1984 y continúa vigente incluso ahora. El JET es la puerta de entrada para la dominación de la fusión nuclear, los datos provenientes del dispositivo han permitido un gran número de investigaciones que se utilizarán para la construcción de ITER, cuya propuesta supone la solución definitiva a los problemas de los distintos dispositivos de fusión nuclear. Parte de la solución es eliminar por completo las interrupciones, o más bien, lograr predecirlas con una tasa de acierto mayor al 95%

Como se puede observar claramente en la Figura 1-4, esta estructura presenta una complejidad menor que la anterior, ya que hay dos juegos de bobinas: la interior y la exterior, estas inducen una corriente en el plasma para generar la componente poloidal del campo magnético. En el caso del stellarator, dicha componente se producía de forma mecánica, por la disposición espacial de los conjuntos de bobinas.




Figura 1-4. Dispositivo Tokamak JET

1.4 Clasificadores

Un clasificador corresponde a un algoritmo que permite determinar a qué categoría pertenece un conjunto de datos dado. Lo anterior explica de manera muy general el objetivo de un clasificador, sin embargo hay una serie de pasos esenciales y muy necesarios para que todo funcione de forma correcta. En primer lugar, siempre que se tiene un gran volumen de datos es indispensable pre-procesar la información para evitar que los datos erróneos sean importantes para el sistema.

Luego del pre-procesamiento, restaría etiquetar cada uno de los datos que entrarán al clasificador con el fin de que el sistema conozca la respuesta que debería esperar de cada uno. Ya con los datos y sus respuestas correctamente etiquetadas se puede comenzar con la etapa del entrenamiento. El entrenamiento consiste en la recopilación de todos los datos pre-procesados en los cuales el algoritmo se aplicará y tratará de generar patrones con la respuesta previamente conocida. Ya con todos los patrones generados y el entrenamiento listo, se empaqueta todo en un modelo y se procede a la etapa de pruebas o “test”. Allí también se conoce la respuesta de antemano, sin embargo ahora se ingresan los datos al modelo y se compara la respuesta del modelo en contraste con la respuesta real del sistema, ya en este punto es posible reconocer la tasa de acierto del sistema.

En la siguiente sección se presentarán alguno de los modelos más utilizados en diversas áreas del aprendizaje automático. Cada uno presenta diversas ventajas y desventajas.

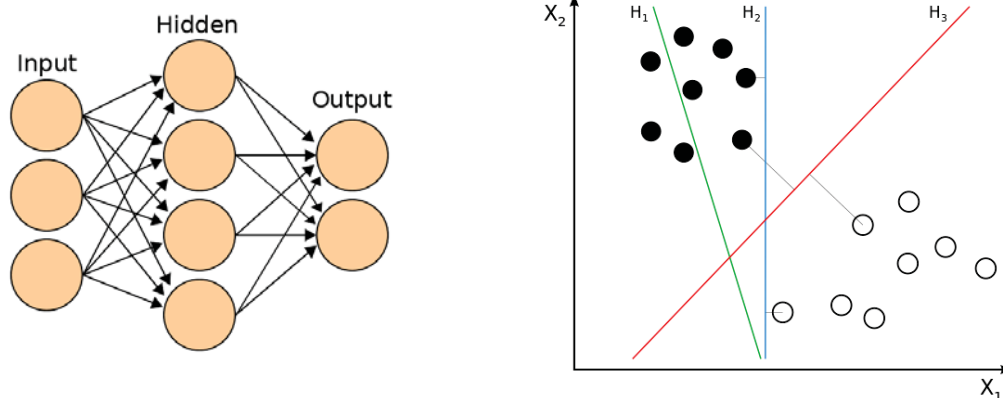


Figura 1-5. A la izquierda una red neuronal. A la derecha una SVM

1.4.1 Redes neuronales

Las redes neuronales son uno de los modelos más usados en aprendizaje automático. Básicamente se trata de una gran cantidad de unidades simples llamadas “neuronas artificiales” [7] simulando el comportamiento del cerebro humano. Estos modelos por lo general alcanzan una tasa de verdaderos positivos aceptables, sin embargo se sacrifica lo transparente del modelo.

Como se puede observar en la Figura 1-5, la columna central representa procesos cuyos cálculos y procedimientos internos no se conocen y tan solo entregan una salida para cierta entrada al sistema.

Cabe destacar que estos sistemas aprenden y se forman a sí mismos, contrario a otros métodos que utilizan algoritmos explícitos para tal fin. El objetivo principal de las redes neuronales es lograr generar modelos que se entrenen de análogamente al cerebro humano. Es interesante mencionar que la potencia de cálculo generada por redes neuronales enormes (millones de conexiones) no es mayor a la de un gusano.

En el año 1943 se creó el primer modelo conocido de redes neuronales basados en matemáticas y algoritmos denominados lógica de umbral. A partir de ese momento empezaron a investigarse diversos métodos que ayudarían a la creación de algoritmos para mejorar la forma de aprendizaje de las máquinas, entre muchos se destaca el Aprendizaje de Hebb y la “Propagación hacia atrás y el resurgimiento”. Ambas explicaciones son extensas y escapan de los objetivos del presente informe.

Cabe destacar que las mejoras en la tecnología fueron un aporte bastante positivo en la aplicación de nuevos métodos de aprendizaje mediante redes neuronales. Y es que la invención de la electrónica de estado sólido elevó la capacidad de procesamiento impresionantemente, tan así que hasta los computadores de escritorio tienen la capacidad de generar pequeñas redes neuronales. Entre los modelos más conocidos está la “Red neuronal recurrente (RNN)” y la “Red neuronal feedforward (FNN)”.

1.4.2 Máquina de vectores soporte

Al algoritmo original fue inventado en 1963 por Vladimir Vapnik y Alexey Chervonenkis. En primera instancia, SVM se utilizaba tan solo en conjuntos de datos separables linealmente, esto complicaba bastante las cosas pues en la mayoría de los casos las tendencias no resultan lineales. Para resolver este problema, alrededor del 1992 el mismo autor propuso una forma de crear el ansiado clasificador no lineal aplicando ciertos métodos a hiperplanos particulares. Vladimir Vapnik aportó considerables mejoras al clasificador durante varios años, así hasta hoy se utiliza para resolver ciertos problemas de clasificación.

De forma muy básica y a modo de ejemplo; el clasificador lineal busca establecer una recta ente dos conjuntos de datos que representen clases distintas [8]. Dicha recta separará los conjuntos de tal forma que la distancia entre ambos sea la máxima posible, aquellas muestras que se encuentren justo en el margen de la separación de las clases se les denominará; vectores soporte..Cabe destacar que una de las grandes ventajas de este método es que no es iterativo y por lo tanto inmune al sobre-entrenamiento.

Como se puede observar en la Figura 1-5, hay tres rectas y dos categorías, representadas por círculos negros y blancos. La recta “H₁” no separa de ninguna forma ambas categorías. La recta “H₂” separa ambas categorías de forma perfecta, sin embargo la distancia entre la recta y uno de los ejemplos es muy pequeña. Cuando se traza la recta “H₃”, la separación entre los ejemplos de una categoría y otra crece bastante y se logra una buena calidad en el SVM.

1.4.3 Métodos ensamblados

Los métodos ensamblados es una forma muy efectiva de mejorar el desempeño de modelos individuales. Consiste en combinar distintos grupos de modelos individuales que por sí solos no alcanzan resultados útiles para ser utilizados de forma real. Sin embargo, una vez que se mezclan y ponderan cada uno de sus modelos pequeños, resulta un clasificador final muy robusto con unas tasas de acierto muy superiores con respecto a otros métodos individuales.

El algoritmo utilizado a lo largo del presente informe consiste justamente en un método ensamblado, este consiste en AdaBoost. Dicho algoritmo es iterativo y solo puede utilizarse si el error en cada una de sus iteraciones no es cero, pues si así lo fuera, este se indeterminaría. La cantidad de iteraciones son escogidas el usuario y generalmente se eligen convenientemente para tener un equilibrio entre tasas de acierto y falsos positivos.

Este algoritmo consiste en la generación de reglas del tipo IF-THEN de manera iterativa, cada regla tiene una ponderación asociada a la importancia de dicha regla en la clasificación final dada alguna entrada al sistema. Además, cada regla tiene un umbral bajo el cual se determina una condición que puede ser positiva (+1) o negativa (-1). Esa condición es la que se compara con la entrada al sistema para determinar si la ponderación asociada es positiva o negativa. Finalmente se genera un polinomio de reglas, cada regla posee un umbral, la ponderación y el signo dado por el umbral (+1 o -1). Para finalizar, el resultado de la sumatoria de todas las ponderaciones

multiplicada por sus reglas generará una salida que tendrá signo negativo o positivo, dicho signo será la hipótesis fuerte y salida del sistema

1.5 Motivación

Los clasificadores modernos de aprendizaje automático pueden alcanzar tasas bastantes altas de acierto y muy bajos falsos positivos. Para efectos prácticos lo anterior puede ser útil y potencialmente aplicable, sin embargo la mayoría de estos modelos contienen procesos internos que se realizan de forma casi totalmente automática, por lo cual se pierde el control y el conocimiento del funcionamiento interno del clasificador.

Es por lo anterior que se busca un enfoque diferente en el presente informe. Se priorizará la utilización de algoritmos que permitan tener conocimiento total de aquellas características que son vitales para realizar clasificaciones correctas.

1.5.1 Sistema de caja negra

El principal problema de los modelos de caja negra es que no se tiene conocimiento de los distintos procesos que se realizan internamente. A continuación se presenta un esquema básico de un modelo de caja negra.

Cuando el modelo se orienta a la clasificación de señales temporales, es muy conveniente tener conocimiento de cómo cada una de las señales va modificando el resultado de las predicciones, de esa manera el operador a cargo de la descarga puede ir modificando ciertas variables en tiempo real y forzar al predictor a que entregue cierto resultado (-1 en este caso).

Por lo general, cuando los modelos son demasiado complejos y se poseen gran cantidad de variables, se opta por utilizar cajas negras. De esa forma se sacrifica el conocimiento por una clasificación más precisa. Es importante señalar que la idea principal de este trabajo es generar pleno conocimiento de las variables que inciden en la toma de decisión del predictor, por lo que queda completamente descartado el modelo de caja negra. Si bien es posible que se obtengan buenos resultados, uno de los objetivos es que un operador pudiese forzar una salida.

Un modelo de caja negra tan solo entregaría la respuesta en cierto instante, por lo que el operador no contaría con el tiempo necesario para tomar una acción que permita disminuir el daño a las paredes del dispositivo.




Figura 1-6. Ejemplo de sistema de caja negra

1.5.2 Sistema de caja transparente

Al contrario que el caso anterior, un sistema de caja transparente permite conocer plenamente el funcionamiento interno de cada proceso. Por lo que en cada etapa del clasificador se sabe el valor de importancia de la señal correspondiente y la respuesta que esta llevará consigo.

Si bien la Figura 1-7 no representa un modelo de aprendizaje automático, se puede apreciar como cada uno de sus bloques tiene variables bien conocidas. Si por alguna razón el operador tuviera acceso a esas variables y quisiera forzar cierta salida lo podría hacer pues se tiene pleno conocimiento de cómo afecta cada una de ellas en cada proceso intermedio.

Este concepto aplicado a aprendizaje automático tiene mucho potencial, pues de conocer los parámetros que aportan cada una de las señales al sistema predictor, un operador podría ir modificando de alguna forma las señales para que se ajusten a la salida esperada del sistema.

Para el algoritmo Adaboost, se conoce en cada iteración la regla que tiene más ponderación por lo que se podría saber con antelación si alguna de las señales está aportando con un valor demasiado negativo o demasiado positivo.

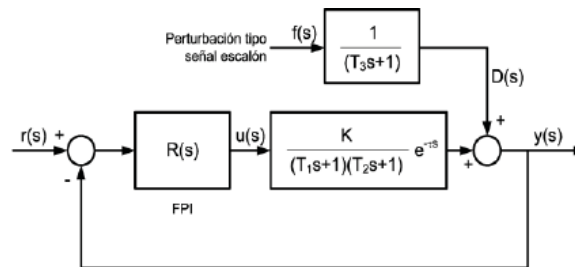


Figura 1-7. Sistema de control realimentado

2 Estado del Arte

A lo largo de los años se han desarrollado múltiples clasificadores cuyo objetivo ha sido solucionar el problema de las disrupciones nucleares. Por lo general, la mayoría de dichos clasificadores utilizan los principios del aprendizaje automático.

A continuación se presentan brevemente los predictores desarrollados hasta la fecha y la comparación entre ellos. Cabe destacar que se indican las técnicas utilizadas, los porcentajes de acierto y su capacidad de implementación en tiempo real.

Tabla 2-1. Algunos métodos desarrollados hasta la fecha

Estudio	Técnica	Aciertos (%)	Falsas alarmas (%)	Alarmas perdidas (%)	Tiempo real	Tiempo antes de disrupción	Predicción tiempo disrupción	Citas
J. Hernandez	RNA	n/a	n/a	n/a	No	1[ms]	No	41
R. Yoshino	RNA	89.5 86 JET, 90 AUG 67	16.6	n/a	No	10[ms]	No	20
C.G. Windsor	RNA	JET→AUG 69 AUG→JET	1- %Aciertos	n/a	No	10[ms] 40[ms]	Si	20
B. Cannas	SOM/RNA	87.23	0.98	23.26	Si	100[ms]	No	12
A. Murari	Fuzzy logic	74	23.5	28	No	100[ms]	No	17
G. Rattá	SVM	92.727	4.5455	0.909	Si	146.23[ms]	No	30

2.1.1 Predictores por redes neuronales

Fue en un dispositivo Tokamak donde se intentó por primera vez desarrollar un sistema de predicción de disrupciones. Dicho dispositivos pertenecía a la universidad de Texas. En este primer caso se utilizaron dos sistemas distintos entre sí, para luego comprar sus resultados. Cabe destacar que se continuó con la misma línea de investigación en estudios posteriores, siempre priorizando las redes neuronales como el sistema predictor por defecto.

Otro sistema que es importante mencionar es aquel en el que se analizaron mediante validación cruzada las descargas provenientes del dispositivo JET y ASDEX Upgrade (AUG). Este tipo de predictor funciona entrenando AUG y testeando en JET y viceversa. Para AUG, el algoritmo logró

una tasa de acierto de alrededor del 90%, mientras que para JET alcanzó cerca del 86%. Sin embargo al realizar la validación cruzada, los algoritmos alcanzaron 69% cuando se entrenó con datos de AUG y 67% cuando se entrenó con datos del JET.

2.1.2 Predictores por lógica difusa

Como puede apreciarse en la Tabla 2-1, tan solo hay un algoritmo de lógica difusa desarrollado por A. Murari. Es importante destacar la baja tasa de acierto de dicho sistema, da cuenta de porque no se siguieron desarrollando algoritmos siguiendo los pasos de lógica difusa. Tan solo se alcanza una tasa de acierto del 74% y falsas alarmas del 23,5%. El algoritmo no tuvo suficiente potencial para trabajarlo con mayor profundidad.

2.1.3 Predictores por SVM (Máquina de vectores soporte)

En esta sección se dará a conocer a APODIS (Advanced Predictor of Disruptions) en el cual se lleva a cabo un análisis sobre un total de 14 señales que son divididas en ventanas de tiempo de 30ms. Para el APODIS se construyeron 3 clasificadores distintos siguiendo la lógica de SVM, en función de las tres respuestas recibidas por los clasificadores, se elabora una función de decisión que determina si finalmente la señal es disruptiva o no. Este predictor ha alcanzado una tasa de acierto de alrededor de 97,7%, muy superior a lo desarrollado mediante lógica difusa.

2.2 Adaboost

Adaboost proviene de “Adaptative Boosting”, este es un algoritmo propuesto por Yoav Freund y Robert Schapire como un método generalizado para obtener clasificadores débiles [1].

El método de Adaboost es pensado en primera instancia para clasificar datos cuya respuesta consista en valores binarios, vale decir con dos posibilidades en su clasificación. Es importante señalar que los “valores” que pueden tomar dicha clasificación se llaman clases y pueden ser -1 o +1. Por ende las clases corresponden a las categorías posibles de los elementos.

Una de las ventajas de Adaboost con respecto a otros métodos de aprendizaje automático es su sencillez. Este algoritmo funciona (al igual que otros) con árboles de decisión, sin embargo en este caso son binarios.

El árbol de la Figura 2-1 se puede entender de la siguiente manera: si el parámetro que se está testeando, asociado a la regla x_1 es menor que 1069,59 entonces es +1, si fuese mayor o igual a ese valor, entonces es -1. El resultado obtenido de la condición anterior debe multiplicarse por un factor de ponderación que está asociado a cada una de las reglas (α_t).

El proceso anterior describe la forma de evaluar una sola regla del modelo asociado. Como se trata de un método ensamblado, éste contiene gran cantidad de reglas. Lo anterior implica que para obtener una hipótesis fuerte se deben recorrer cada una de las reglas y cada resultado parcial (hipótesis débil) se debe sumar algebraicamente para obtener un resultado cuyo signo será la decisión de la hipótesis fuerte. La hipótesis fuerte corresponde a la respuesta final del modelo generado y cuyo valor corresponde a la categoría (o clase) de los datos analizados.

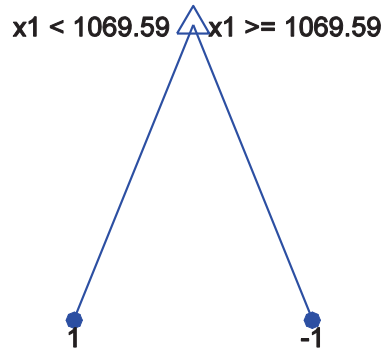


Figura 2-1. Ejemplo de árbol de decisión

2.3 Ejemplo ilustrativo

En la Figura 2-2 se puede observar el algoritmo Adaboost descrito paso a paso. De forma particular en relación a otros algoritmos, Adaboost inicia con una distribución igualada de los pesos para cada una de las muestras. Este clasificador consiste en la generación de T modelos sencillos, donde T sería la cantidad de iteraciones elegida según sea necesario. Cabe destacar que estos modelos no son generados aleatoriamente, sino que dependen fuertemente del error de clasificación obtenido en el caso anterior. Esta es la manera en la que Adaboost mejora la tasa de acierto iteración a iteración.

Con el fin de fortalecer aún más el entendimiento de Adaboost, en esta sección se presentará un ejemplo ilustrativo. En él se reflejarán los aspectos más importantes a considerar para el correcto funcionamiento del algoritmo.

```

AdaBoost algorithm

Input:  $S = \{(x_i, y_i), \forall i = 1 \dots m\}$ 
#S: Training set example
# $D_1$ : Initial weight distribution
#m: Size of the training set
# $y_i \in \{-1, +1\}$ 
 $D_1(i) = \frac{1}{m}, \forall i = 1 \dots m$ 
#T iterations are performed
for  $t := 1$  to  $T$  do
  # Get weak hypothesis  $h_t: X \rightarrow \{-1, +1\}$ 
   $h_t = \text{GetWeakHypothesis}(X, D_t)$ 
   $\epsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i)$ 
   $\alpha_t = \frac{1}{2} \ln \left( \frac{1 - \epsilon_t}{\epsilon_t} \right)$ 
  #Update  $D_t$  distribution
   $D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t}, \forall i = 1 \dots m$ 
  # $Z_t$ : Normalization factor such that  $D_{t+1}$  is a distribution:
  # $Z_t = \sum_{i=1}^m D_t(i) \exp(-\alpha_t y_i h_t(x_i))$ 
end for

return hypothesis combination:  $f(x) = \sum_{t=1}^T \alpha_t h_t(x)$ 

end AdaBoost

```

Figura 2-2. Algoritmo Adaboost

El objetivo es clasificar un conjunto de datos de dos dimensiones, cuya ubicación en el plano cartesiano corresponde a los ejes X e Y, en adelante denominados como X_1 y X_2 respectivamente.

La Tabla 2-2 contiene los datos de entrenamiento del ejemplo ilustrativo, estos datos serán los que ingresaran al sistema predictor para generar las salidas (respuesta) correspondientes. Aquellas muestras con la clase +1 corresponden a los círculos rojos y con la clase -1 corresponden a las cruces azules.

En la Figura 2-3 se puede observar la representación en el plano cartesiano de los datos expuestos en la Tabla 2-2. La idea principal del ejemplo ilustrativo es lograr plasmar gráficamente un algoritmo completamente textual. De esta forma se comprobará el funcionamiento en completitud.

Antes de comenzar el entrenamiento, se deben establecer algunas normas que permitirán normalizar la forma en la que se tratarán los problemas de ahora en adelante, por ejemplo; los umbrales escogidos siempre significaran un +1 en la clasificación, por lo tanto si se establece que $X_1 > 3$, entonces significará que el sistema impone que todas las muestras cuyo valor de X_1 sea mayor que tres, tendrán una clasificación de +1. Aquellos valores que estén mal clasificados serán los errores del sistema y son de especial importancia para los procesos posteriores.

Como se dijo anteriormente, el algoritmo Adaboost siempre busca reducir el error asociado a las reglas de forma iterativa. En una primera iteración es sencillo pues como cada muestra tiene el mismo peso asociado, simplemente se escogerá aquella regla (o umbral) que permita la menor cantidad de errores en una primera clasificación.

En la Figura 2-4 se puede observar la primera regla. Como se explicó anteriormente, el algoritmo escoge la primera regla en aquel lugar en el que se produce el menor error. La regla correspondiente a la figura sería $X_1 < 3,5$. Con dicha regla se logra la mejor clasificación pues tan solo falla en una ocasión. La muestra que falla corresponde a la séptima, adjunta en la Tabla 2-2. Para comprender cómo el algoritmo selecciona las reglas subsiguientes, tanto en la Figura 2-4 como en la Figura 2-5, las muestras que fueron mal clasificadas en cada iteración se aumentó su tamaño para representar lo que sucede en la tabla de los pesos asociados a cada muestra en cada iteración. Es importante destacar que la tabla de pesos se actualiza al final de cada iteración y le indica al algoritmo las muestras a las que se debe prestar más atención en las siguientes reglas.

Para la selección de las próximas reglas, ya no basta con elegir aquella que tiene menos errores o que falla menos veces. Ya después de la primera iteración, el peso asociado a cada muestra es de especial importancia pues incide en el cálculo del error de cada muestra y dicho error permite discernir la posición del umbral.

Para este ejemplo ilustrativo y de forma totalmente empírica, se decidió iterar tan solo tres veces pues en caso contrario se perdería la lógica de un ejemplo simple y, además, las reglas se iban repitiendo constantemente con distinta ponderación.

En la Tabla 2-4 se muestran las ponderaciones asociadas a cada una de las tres reglas calculadas en cada proceso. El valor de estas ponderaciones indicará la importancia de las reglas, por lo que

a mayor valor, mayor será la importancia. Como se puede observar, todas las ponderaciones tienen valores bastante parecidos, sin embargo la última es la más importante y por lo tanto es aquella que influenciará en mayor medida la clasificación.

Tabla 2-2. Conjunto de entrenamiento ejemplo ilustrativo

n	X1	X2	Clase
1	1	4	+1
2	2	5	+1
3	1	1	+1
4	2	1	+1
5	5	5	-1
6	5	4	-1
7	1.5	0.5	-1




Figura 2-3. Representación en el plano cartesiano

Una vez que se completan las iteraciones se obtiene el modelo final que permitirá clasificar nuevas muestras que no sean las que se utilizaron para entrenar. Esto se hace en la etapa final del algoritmo mediante una sumatoria del producto entre las hipótesis débiles obtenidas en cada iteración y las ponderaciones correspondientes a cada una de dichas hipótesis. En la Tabla 2-5 se propone una muestra para realizar la clasificación paso a paso. En la ecuación (2-1) se puede apreciar claramente cómo se van ponderando cada una de las reglas. El valor de la hipótesis débil depende del valor que se le asigna según los modelos individuales y la posición de la muestra.

Tabla 2-3. Distribución de pesos segunda iteración

X1	X2	D2
1	4	0,08
2	5	0,08
1	1	0,08
2	1	0,08
5	5	0,08
5	4	0,08
1.5	0.5	0,5

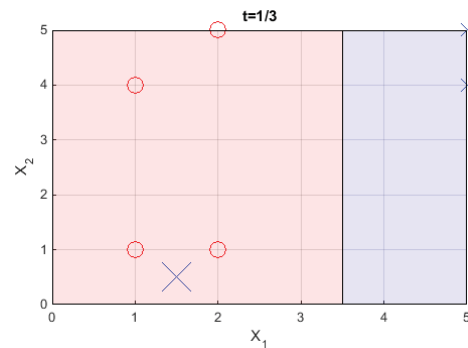


Figura 2-4. Primera regla




Figura 2-5. Iteración 2 y 3 ejemplo ilustrativo

Tabla 2-4. Ponderaciones asociadas a cada iteración

Ponderaciones
$\alpha_1 = 0,89$
$\alpha_2 = 0,80$
$\alpha_3 = 1,10$

Tabla 2-5. Punto de prueba Adaboost

X_1	X_2	Clase
2,5	3	?

$$\begin{aligned} \text{sign}\left(\sum_{t=1}^3 \alpha_t \cdot h_t(x)\right) &= \text{sign}(0,89 \cdot (+1) + 0,80 \cdot (+1) + 1,1 \cdot (-1)) \\ &= \text{sign}(+0,59) = +1 \end{aligned} \quad (2-1)$$




Figura 2-6. Test de mil muestras aleatorias

El ejemplo puede extenderse para visualizar la distribución de las clases en el plano cartesiano. En la Figura 2-6 se muestra la clasificación de mil muestras distribuidas aleatoriamente en los límites establecidos por las muestras de prueba.

Con este ejemplo se logró verificar con la facilidad que se pueden lograr buenas clasificaciones y en unos pocos pasos con una muy pequeña exigencia computacional.

3 Análisis temporal de señales

En esta sección se explicarán los métodos utilizados para analizar las señales provenientes de los sensores del JET. Se busca principalmente generar resultados sencillos a base de señales complejas y de esa manera reducir al mínimo tanto los tiempos de procesamiento como la complejidad del sistema predictor completo.

3.1 Señales analizadas

En las siguientes secciones se darán a conocer aquellas señales que se utilizaron a lo largo de todos los experimentos y se añadirá una pequeña explicación de cómo se utilizan y el por qué son importantes para lograr una buena clasificación y obtener las tasas esperadas durante el presente trabajo.

3.1.1 Mode Lock

La señal Mode Lock ha sido ampliamente utilizada en numerosos predictores y trabajos investigativos, esto principalmente porque comienza a aumentar considerablemente. El aumento se produce cuando una inestabilidad macroscópica comienza a bloquearse en las paredes del JET, luego el plasma empieza a detener su rotación gradualmente y la señal Mode Lock crece [9].

3.1.2 Evolución temporal de la afluencia del Tungsteno

Señal de uso reciente, se ha observado un comportamiento típico al momento de la disrupción y se planteará su uso con diversos procesamientos de la señal temporal. Básicamente como se trata de la primera capa para que el plasma no escape, su nivel de afluencia debería aumentar conforme la disrupción se vuelve inminente [10].

3.1.3 Energía diamagnética

Esta señal se ha ocupado en trabajos anteriores. En esta oportunidad se planteará otro método para tratarla y así obtener buenas predicciones. También se observa un comportamiento disruptivo que podría ser potencialmente predecible.

3.1.4 Potencia de entrada y potencia radiada

Corresponden a un conjunto de señales que tienen que ver con la energía inyectada al sistema y una porción de la potencia irradiada por sus campos electromagnéticos [11]. Con estas señales se busca una nueva señal sin unidad cuya amplitud corresponde a la división instantánea de ambas.

3.1.5 Señales bolométricas

Corresponden a un conjunto de señales que miden las pérdidas por radiación del plasma en distintas secciones del Toroide de forma temporal [12]. Se tratan de bolómetros ubicados en posición estratégica para observar el desarrollo tanto espacial como temporal de estas pérdidas.

Con estas señales se busca determinar concentraciones de plasma que estén cercanas a alguna de las paredes, ya sea en vertical u horizontal. Se plantea como alternativa a la señal Mode Lock y como una forma de generar un modelo orientado a la evitación de la disrupción.

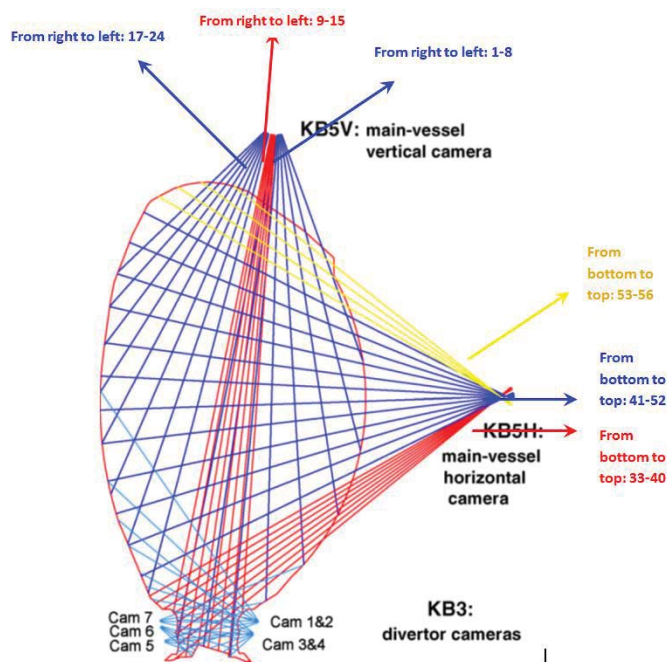


Figura 3-1. Ejemplo extracción de señales bolométricas

3.2 Acotamiento por corriente de plasma

Uno de los primeros filtros esenciales para analizar todas las señales provenientes del JET es el acotamiento que se realiza por medio de la Corriente de Plasma. Por lo general se prefiere que el acotamiento sea del orden de 750kA [13] para asegurar que exista plasma al interior del toroide. En diversas ocasiones y a modo de experimentación se ha establecido un acotamiento a 1000kA de corriente de plasma en algunas pruebas, mejorando así los resultados de forma ocasional.

Para ilustrar la idea del acotamiento, a continuación se presentan dos imágenes. En la Figura 3-2 a la izquierda se observa una descarga Mode Lock disruptiva antes de ser acotada, por otro lado,

la imagen de la derecha muestra la misma descarga, pero esta vez recortada con la condición descrita previamente de la corriente de plasma. En esta oportunidad pareciese no ser muy relevante el hecho de recortar o acotar la descarga, pero en otras instancias sucede que existen inestabilidades al inicio de la misma que pueden ser perjudiciales para entrenar un clasificador.

Como se puede apreciar en la Figura 3-2 de la derecha, justo al inicio de la señal existe un pequeño espacio vacío en el que algunos datos fueron eliminados por no cumplir la condición de acotamiento de la corriente de plasma. Esto nos indica que es probable que en ese instante no existía plasma al interior del toroide.

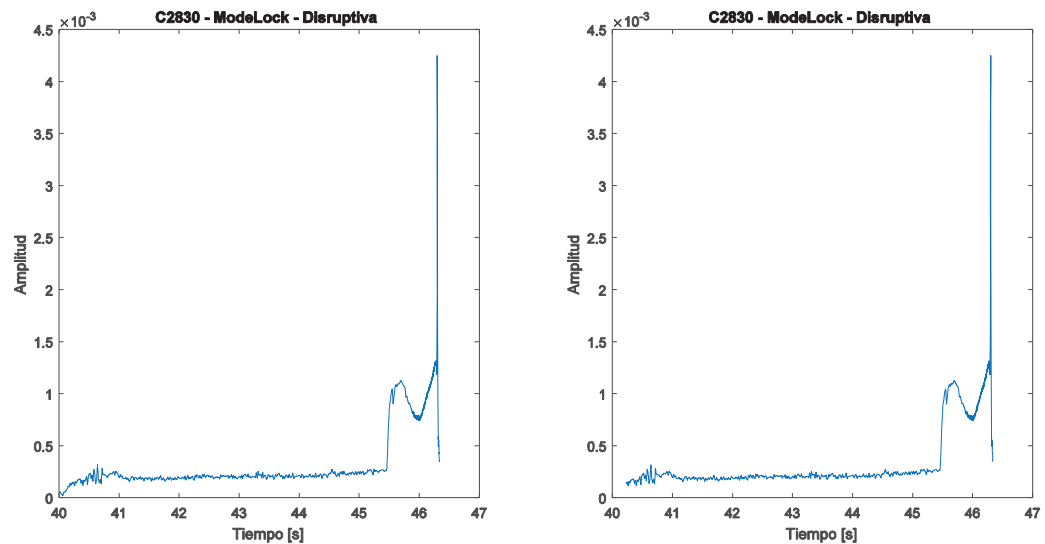


Figura 3-2. Comparación entre dos descargas; una sin acotar y otra acotada

3.3 Concepto de Warning Time (WT)

El warning time (WT) es el tiempo que hay entre que se detecta la disrupción y ocurre la misma. Se calcula de la siguiente forma:

$$WT = t_{dis} - t_{detect} \quad (3-1)$$

A lo largo de este trabajo siempre se ha pensado la implementación de un clasificador final en tiempo real sobre un dispositivo de fusión nuclear. Es por lo anterior que se requiere de una métrica que permita reconocer la capacidad del modelo para entregar resultados con suficiente tiempo de antelación para que los operadores se permitan un tiempo de acción suficientemente alto y así evitar daños catastróficos.

El Warning Time es fundamental para evaluar la calidad de los distintos modelos generados. Un modelo que entregue tasas de acierto muy altas con un WT bajo no servirá para casos prácticos y deberá descartarse. Es importante destacar que las disrupciones son eventos muy rápidos por lo que si el modelo predice una disrupción 30ms antes de que ocurra, no se podrán tomar acciones de evitación o mitigación, simplemente se dañarán las paredes del toroide y diversos componentes internos. Asimismo, si la disrupción se predice mucho antes que un segundo

también se considera un mal pronóstico pues los físicos expertos determinan que es imposible que una disrupción comience a manifestarse con un segundo de anticipación. A continuación se presentará una imagen que clarificará la idea del warning time y también de su cálculo, mostrando gráficamente el intervalo al que pertenece.

En la Figura 3-3 se muestra una descarga disruptiva Mode Lock. Dicha descarga es un poco distintas a las vistas anteriormente porque se encuentra ampliada en aquel intervalo cercano a la disrupción. El asterisco rojo muestra el instante en el que el experto indicó que ocurría la disrupción (o el evento disruptivo). En verde se muestra el instante en el que el predictor dio como respuesta una disrupción. El tiempo que existe entre ambos instantes es lo que se denomina Warning Time.

Como se mencionó anteriormente, el WT incide directamente sobre las métricas que determinan si el modelo acertó o no. A continuación se presentan cada uno de los conceptos que se darán por entendido más adelante. También se especifica como calcular las tasas de acierto y de falsos positivos.

Es importante señalar que significa cada uno de los conceptos que se verán a continuación:

- ❖ Valid Alarm (VA): Corresponde a una detección disruptiva que ocurre entre 30ms a 1s
- ❖ Premature Alarm (PA): Detección disruptiva que ocurre antes de 1s
- ❖ Tardy Detection (TD): Detección que ocurre entre 30ms o menor.
- ❖ Success Rate (SR): Corresponde a la suma de los tres términos anteriores VA+PA+TD
- ❖ False Positives (FP): Corresponde a aquellas señales safe clasificadas como disruptiva

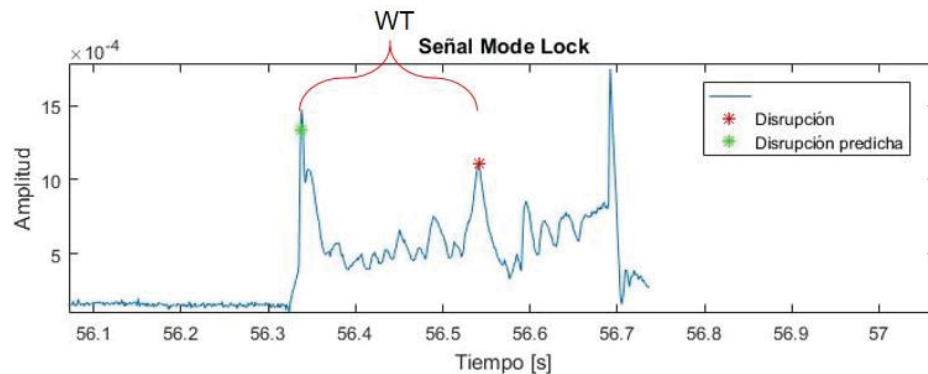


Figura 3-3. Ejemplo ilustrativo WT

3.4 Enfoque de centroides

El enfoque de centroides surge como una posible solución para reducir el warning time y aumentar la tasa de acierto en los clasificadores.

La idea básica detrás del enfoque de centroides consiste en una especie de compresión de las descargas pues se intenta reducir una señal completa en tan solo una muestra. Para determinar los centroides primero se deben calcular los conjuntos de muestras asociadas a cada clase. Después se debe determinar el promedio de las posiciones de cada eje por separado para obtener el centroide de los datos.

En este punto ya los datos provenientes de las señales pierden su propiedad temporal pues su eje X se vuelve irrelevante al entrenar mediante este método. Simplemente se les asigna a cada muestra un número dependiendo de la posición que ocupaban previamente en el tiempo, esto significa que inician en uno correlativamente hasta el final. Lo anterior implica que habrá muestras que tendrán posiciones pares y posiciones impares en el plano cartesiano, detalle vital para este tipo de procesamiento. En la Figura 3-4 se puede apreciar una distribución de muestras con sus respectivos centroides.




Figura 3-4. Ejemplo ilustrativo centroides

3.4.1 Centroide descarga disruptiva

Las señales provenientes de las bases de datos contienen el tiempo exacto en el que ocurre la interrupción. Para transformar cada una de las descargas en una simple muestra del plano cartesiano se debe considerar la amplitud que tiene esa descarga en el instante más cercano a la interrupción. Dicho dato corresponderá al eje Y de la muestra y el dato justo anterior a ese será el eje X de la muestra. Lo anterior debe ejecutarse para cada una de las descargas disruptivas y posteriormente se promedian cada una de las muestras para extraer su centroide.

Es importante destacar que el instante escogido debe cumplir con cierta condición y es que no se puede encontrar en un tramo decreciente. Lo anterior implica que el dato correspondiente al eje Y de la muestra debe ser mayor al dato asociado al eje X de la misma muestra, de esa forma nos aseguramos que se encuentre en un tramo creciente.

3.4.2 Centroide descarga safe

En aquellas descargas que no generaron una interrupción no intencionada se hace un trabajo distinto. En este caso se considera la descarga completa para el análisis y no solamente el instante disruptivo como pasó anteriormente. Para extraer una muestra safe se toman los datos ubicados en posición par y se extrae su promedio simple, dicho promedio corresponderá al eje X de la muestra. Análogamente se toman los datos impares de la descarga y también se promedian, en este caso ocuparán el eje Y de la muestra.

El método anteriormente expuesto permite determinar una tendencia relativamente fiable. La mayoría de las descargas safe tienen comportamiento similares, por lo que los valores que alcanzan se encuentran en un rango bastante predecible. Lo anterior permite la generación de conjuntos de muestras que tendrán muy poca variación y estén bastante cercanos con su centroide. Cabe destacar que el enfoque de centroides sigue la misma tónica orientada al clasificador en tiempo real y es potencialmente realizable. Además, el tiempo de procesamiento para este tipo de enfoque es casi nulo, pues solo basta recopilar la información de la descarga de forma ordenada y tan solo procurando no perder demasiados datos en el camino pues ligeras variaciones como un dato vacío o una división por cero podrían ocasionar que se genere una indeterminación en el modelo o la necesidad de validaciones excesivas.

3.5 Enfoque de Peaking Factor

El *peaking factor* surgió como una idea de analizar dos señales que tuviesen las mismas unidades en su magnitud en conjunto y de esa forma encontrar alguna tendencia asociada a la interrupción. En este caso particular se busca que tengan las mismas unidades en su magnitud porque para realizar un análisis por Peaking Factor se requiere una división instantánea entre ambas descargas, vale decir una división punto a punto solo de sus magnitudes.

El peaking factor se trabaja con las señales provenientes de los sensores bolométricos que entregan información exacta de la distribución del plasma entre distintas zonas del toroide. Con dicha información se busca cambios bruscos de la posición del plasma, lo que sería análogo a la velocidad del plasma.

Se eligieron 3 canales de zonas distintas del toroide; uno central y dos ubicados en los extremos del mismo. Esto supone un estudio en las variaciones de plasma en dichas zonas y con las divisiones temporales se podrían obtener curvas crecientes o decrecientes dependiendo de la dirección que vaya tomando el plasma. Cabe destacar que el caso ideal es que el plasma se concentre en el centro del toroide y cualquier movimiento o estancamiento hacia las paredes indicaría una inminente interrupción.

La Figura 3-5 muestra el resultado de una división instantánea entre dos descargas provenientes de los canales bolométricos. A simple vista pareciese no tener sentido alguno, sin embargo esto es causado de forma muy probable por pérdida de datos al momento de recopilar información. El enfoque de peaking factor es muy sensible a la mala recopilación de datos y a los cambios abruptos entre muestra y muestra. Lo que se observa en la figura se le reconoce normalmente

como *outlier*; datos que escapan de la tendencia o simplemente datos faltantes que se rellenan automáticamente con ceros o números muy cercanos a cero.

Cuando los datos faltantes se rellenan con números muy pequeños, la división se dispara y ocurre un outlier. Existen diversas técnicas que solucionan la situación. En este caso, como se tratan de datos que representan fenómenos de la naturaleza, se optó por el filtro MAD, muy conocido y bastante robusto para detectar estos cambios abruptos en grandes volúmenes de datos. En la ecuación (3-2) corresponde a los índices normalizados mediante el filtro MAD.

$$M_i = \frac{0,6745 \cdot (x_i - \hat{x})}{MAD} \quad (3-2)$$

Donde MAD es la desviación mediana absoluta. En [14] se recomienda eliminar aquellos valores en los que el resultado sea mayor a 3,5 ya que en ese caso se trata de un outlier.

Como se puede observar en la Figura 3-6, el filtro de outlier no es suficiente para obtener una señal limpia con datos potencialmente clasificables. Es por eso que se hace necesario realizar procesamientos un poco más complejos para obtener resultados coherentes. Con el fin de explorar nuevas soluciones a los problemas que fueron surgiendo y como la señal obtenida seguía siendo muy indescifrable se propuso un filtro que seguía la misma tónica que el procesamiento RMS. Como dicho filtro solo funciona con aquellas señales que son periódicas es que se analizó todo considerando un periodo de 8ms.

Básicamente se estudió la señal dividiéndola en secciones que sean equivalentes con el periodo escogido. En [15] se puede encontrar la ecuación necesaria para el cálculo de RMS en señales que son continuas en el tiempo. En la Figura 3-7 puede apreciarse la señal resultante después de aplicar el filtro RMS a la señal previamente filtrada con los outlier.

$$Y_{ef} = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} y^2(t) dt} \quad (3-3)$$

De manera meramente ilustrativa se presenta en la Figura 3-8 la señal filtrada mediante RMS superpuesta con la señal filtrada mediante outlier. Puede apreciarse claramente como el resultado mejora notoriamente y los datos tienen tendencias notorias. Este método supone un alto coste computacional y también mucho riesgo de aleatoriedad, no asegurando la integridad de un análisis limpio de datos. Es por lo anterior que el método se descartó por completo, pues se alejaba de la tónica y de los objetivos del presente trabajo.

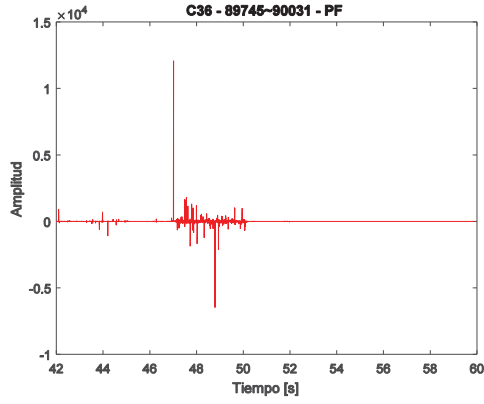


Figura 3-5. Peaking factor bolométricas




Figura 3-6. Filtro de outlier aplicado

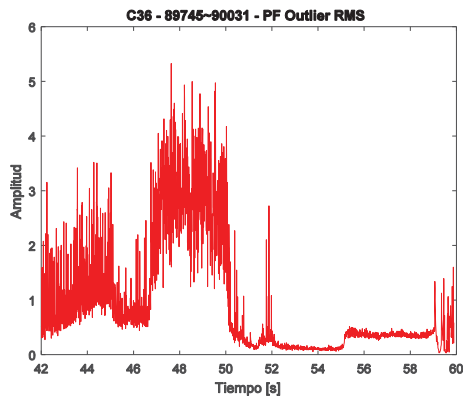


Figura 3-7. Filtro RMS aplicado

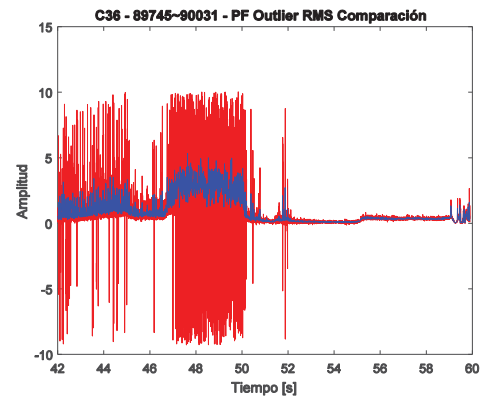


Figura 3-8. Filtro RMS aplicado y superpuesto

3.6 Enfoque de ventanas

En la siguiente sección se presentarán los conceptos necesarios para comprender el enfoque de ventanas que servirá para generar un modelo implementable en tiempo real.

El enfoque basado en ventanas temporales ha sido realizado con los datos de la Campaña 2830 del JET, esta campaña posee todas las señales muestreadas a 1ms, es decir que cada 1ms se obtiene un dato y se guarda en la base de datos correspondiente. Como las descargas pueden llegar a durar hasta 30s, el tamaño de cada descarga es extremadamente grande, esto hace necesario realizar un procesamiento previo para disminuir la cantidad de datos y generar clasificadores más robustos y eficientes. Para realizar lo anterior se usó el concepto de ventana temporal. Las ventanas temporales corresponden a un conjunto de datos (que en este caso se hacen de 32ms) al que se les aplica un procesamiento y se convierten en un solo dato. Algunos ejemplos de procesamiento son: promedio, varianza, pendientes, entre otros. A continuación se presenta un gráfico en que se muestra una descarga disruptiva muestreada a 1ms en contraste con la misma descarga aplicando el concepto de ventana temporal con el procesamiento “promedio”.

Tal como se ve en la Figura 3-9, la descarga promediada presenta un comportamiento bastante similar. El detalle importante es que el peak de su amplitud se ve reducido porque se promedia con toda la vecindad presente en ese instante. También cabe destacar que en el proceso se pierde un poco de resolución, existen menos cantidad de datos y por lo tanto existe algo de pérdida de información, sin embargo la ventaja es la considerable reducción del tamaño de la descarga: el gráfico de la izquierda contiene 6107 mientras que el de la derecha contiene tan solo 190, esto sería aproximadamente el 3% de la señal original.

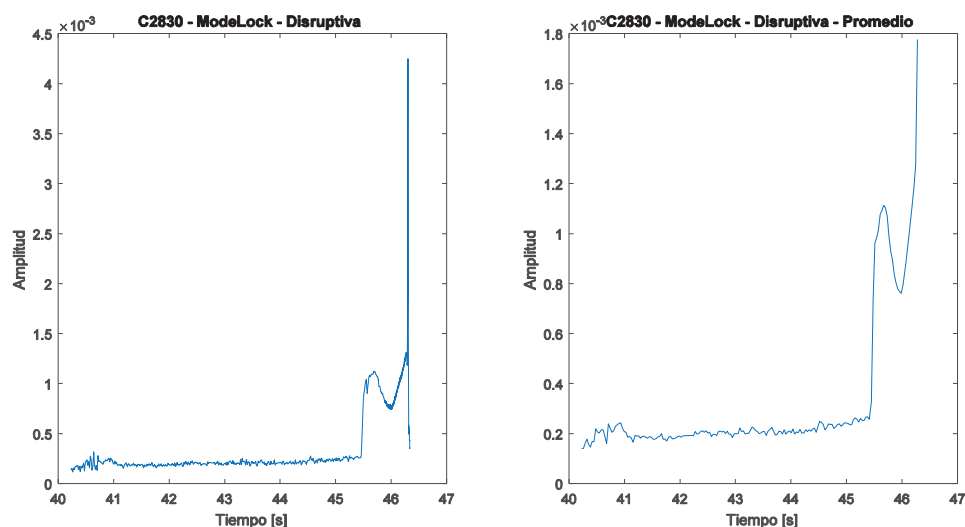


Figura 3-9. A la izquierda la descarga muestreada a 1ms y a la derecha con ventanas promediadas a 32ms

3.6.1 Clasificador en cascada

Paul Viola y Michel J. Jones propusieron en 2001 un algoritmo que permitiría clasificar, en primera instancia, rostros en tiempo real. Dicho algoritmo, además de eso podría eliminar fondos dentro de las imágenes de forma rapidísima y concentrar todo el esfuerzo computacional en aquellas zonas que tienen parecido a un rostro humano [16]. Como es de esperarse, un algoritmo que fue diseñado inicialmente para clasificar puramente imágenes pareciese no ser aplicable a señales temporales o algún otro tipo de distribución de datos. Contrario a lo que se piensa, los resultados mejoraron bastante aplicado el concepto principal del Viola-Jones

Otro concepto importante que se aplica en el enfoque de ventanas es la utilización del clasificador en cascada. Algunas implicancias de su uso es la particular división de sus datos. Se debe hacer una división en dos ocasiones. En primer lugar se dividen los datos globales en dos conjuntos con la proporción 60/40, 60% de los datos para entrenar y 40% para hacer el test. De ese 60% se vuelven a dividir los datos con la misma proporción anterior de 60/40 y se realiza la primera etapa.

Como se puede observar en la Figura 3-10, se realiza una primera división global de los datos. Cuando se realiza el First Test, se espera una tasa de acierto (Success Rate) del 100% y una tasa de Falsos Positivos del 50%. Luego se crea un segundo modelo con toda la Disruptive Data de la primera división y todas aquellas descargas que fueron mal clasificadas como disruptivas. Tras hacer un Global Test de ese segundo modelo, se espera una tasa de acierto de 95% y una tasa de falsos positivos del 5%.

Lo anterior es particularmente útil cuando se analizan conjuntos de datos que tienen un fuerte desbalance. En este caso la cantidad de descargas safe superan con creces a la cantidad de descargas disruptivas. Una vez que supera la primera etapa, los datos se encuentran con un balance muy superior al anterior pues se descartan a lo menos el 50% de las descargas safe.

El principal objetivo en esta sección es generar dos modelos que se utilizará en conjunto para determinar qué tan potente será el clasificador en cascada. La explicación del recuadro correspondiente a “Global Test” se realizará más adelante pues la idea en esta etapa es clarificar tan solo cómo se generaron los modelos utilizados.

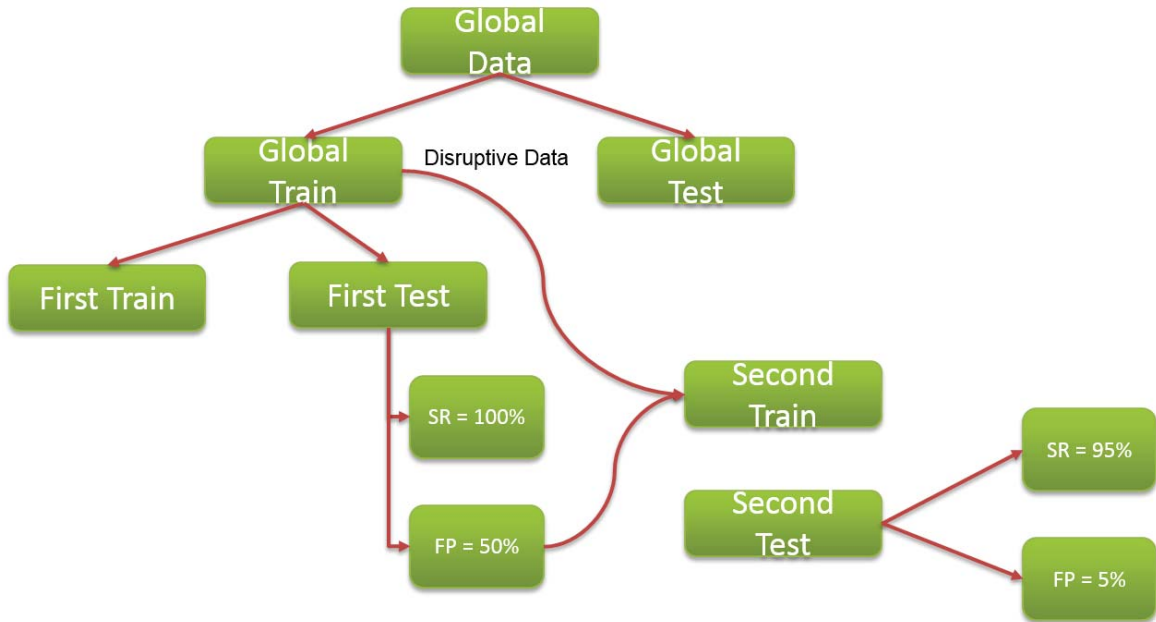


Figura 3-10. Esquema de división de datos

3.6.2 Selección de datos

Para la selección de los datos utilizaron tres criterios:

- ❖ El primero consiste en utilizar el último dato de la descarga disruptiva. En ese instante se considera que ocurre la interrupción, es el tiempo más cercano a la interrupción. Para el caso de la descarga safe (o no disruptiva) se promedian todos los datos de la descarga y eso ingresa al modelo como dato safe.
- ❖ El segundo criterio es el mismo para la descarga disruptiva, sin embargo para la descarga safe se hace algo diferente. Se crea una semilla generadora de datos aleatorios (para replicabilidad) y luego para la primera etapa se escogen 6 datos aleatorios de las descargas. Para la segunda etapa se escogen 10 datos aleatorios de cada descarga.
- ❖ El tercer y último criterio consiste simplemente en etiquetar una sección central de la descarga safe cuyo tamaño varía en función del tamaño de la descarga.

De estos tres criterios se prefirió utilizar el segundo y tercero solo de forma empírica pues fue con el que se obtuvieron mejores resultados, tanto en la primera como en la segunda etapa.

3.6.3 Ventana deslizante

El concepto de ventana deslizante se utiliza bastante cuando se requiere explorar y analizar la evolución temporal de distintos conjuntos de datos.

El test del sistema completo se hizo bajo el concepto de ventana deslizante. Esto quiere decir que la evolución de las características se van actualizando ventana a ventana, sin considerar la ventana anterior y mucho menos la ventana siguiente. Esta forma de hacer el test asegura su funcionamiento en tiempo real y permite comprobar los resultados con los modelos generados con anterioridad.

En este caso es de especial interés la aplicación de este tipo de test pues es necesario detenerlo cuando se encuentra una interrupción además de etiquetar la descarga. Muchas veces, las ventanas temporales no contemplan una sola señal, sino que un conjunto, lo que generaría un vector de características en cada posición de la ventana deslizante.

4 Experimentos y resultados

En esta sección se darán a conocer todos los resultados obtenidos durante la experimentación de los distintos enfoques, además se mostrarán todos los resultados parciales y explicaciones que sean necesarias para complementar el proceso.

4.1 Experimento con centroides

En esta sección se verán los experimentos realizados con el enfoque de centroides (ver sección 0). Aquí se incluirán sus respectivas tasas de aciertos, de falsos positivos y los tiempos en los que se logró la predicción disruptiva. Dichos datos son de importancia para establecer comparaciones entre distintos métodos propuestos anteriormente.

4.1.1 Centroides con señal Mode Lock

El fin de experimentar con la señal Mode Lock es verificar que los métodos de análisis utilizados se ajustan a los resultados obtenidos anteriormente con modelos más antiguos. A continuación se presenta un plano cartesiano en el que observa la distribución de los conjuntos de muestras.

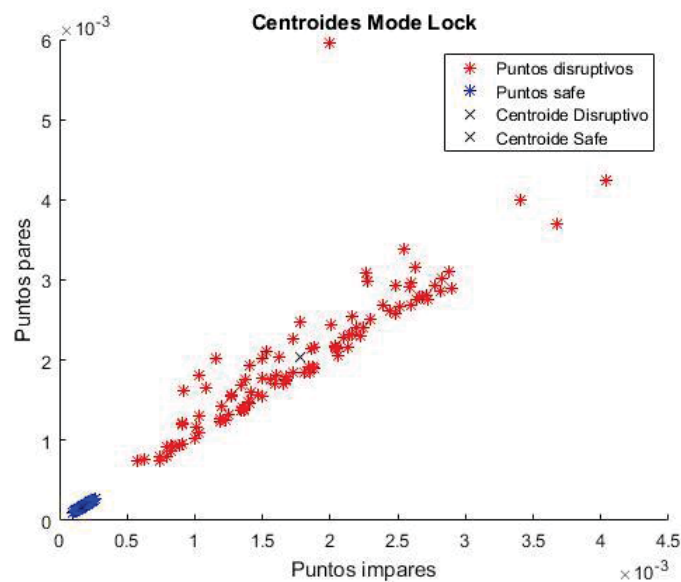


Figura 4-1. Centroides señal Mode Lock

En la Figura 4-1 se puede observar como ambos conjuntos de muestras se encuentran totalmente separadas, logrando así una buena clasificación.

En particular para este test, se tienen dos resultados; aquellos obtenidos aplicando una regla simple que indica que si la distancia del punto de test hacia el centroide disruptivo es menor que la distancia al centroide safe, entonces la descarga es disruptiva. En caso contrario, es safe. Y el otro es utilizar Adaboost para la clasificación.

La implementación en tiempo real arrojó los siguientes resultados:

- ❖ Regla simple
 - VA: 37%
 - TD: 51%
 - PA: 2%
 - SR: 90%
 - FP: 0%
 - Promedio WT: 125,7[ms]
 - Desv. Estándar WT: 548,6[ms]
- ❖ Adaboost
 - VA: 8%
 - TD: 1%
 - PA: 91%
 - SR: 100%
 - FP: 0%
 - Promedio WT: 12,31[s]
 - Desv. Estándar WT: 5,93[s]

4.1.2 Centroides con señal Nivel de afluencia del Tungsteno

El uso de esta señal surge de la búsqueda de nuevas formas que no incluyan la señal Mode Lock en la clasificación de descargas disruptivas. A continuación se muestra una descarga disruptiva de la señal indicada en el título. Cabe destacar que posee un comportamiento bastante predecible con una tendencia creciente al instante cercano a la disrupción.

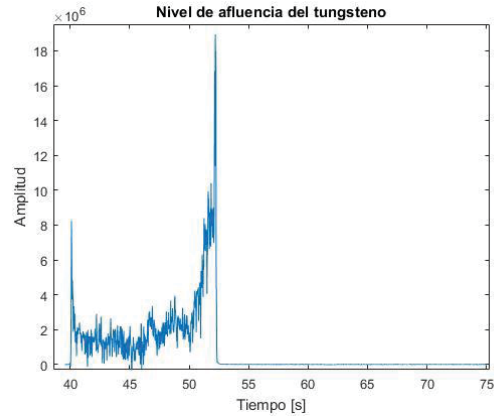


Figura 4-2. Descarga disruptiva Nivel de afluencia del Tungsteno




Figura 4-3. Conjunto de muestras W

En la Figura 4-3 se aprecia la distribución de las muestras tanto disruptivas como safe. En este caso las diferentes distribuciones no se encuentran fuertemente separadas, sino más bien se traslapan una con otra, haciendo que sea compleja la clasificación mediante una regla simple que actúe directamente sobre el análisis de las distancias.

Para los distintos tipos de enfoques, la clasificación en tiempo real de esta señal arrojó los siguientes resultados.

- ❖ Regla simple
 - VA: 32,39%
 - TD: 9,86%
 - PA: 23,94%
 - SR: 66,2%
 - FP: 14,66%
 - Promedio WT: 1,14[s]
 - Desv. Estándar WT: 1,72[s]
- ❖ Adaboost
 - VA: 8%
 - TD: 1%
 - PA: 91%
 - SR: 100%
 - FP: 0%
 - Promedio WT: 12,31[s]
 - Desv. Estándar WT: 5,93[s]

Si bien con Adaboost se logra una clasificación perfecta. Los tiempos asociados al WT son demasiado grandes. Esto implica que la alarma se está disparando todo el tiempo casi al inicio de la descarga.

4.1.3 Centroides con señal Energía diamagnética

La energía diamagnética no presenta un comportamiento tan obvio como las otras señales, sin embargo se puede observar un *falling* justo antes de que ocurra la disrupción como puede observarse claramente en la Figura 4-4. Como el comportamiento de la señal no es claramente disruptivo, es probable que los centroides no estén suficientemente separados y las tasas de acierto no sean las esperadas. Lo anterior puede comprobarse luego de extraer los centroides de las distintas descargas de esta señal, basta observar la Figura 4-5 para notar que no existe una distribución separada de las muestras.

Tal como se esperaba, los centroides presentan un comportamiento muy irregular, a diferencia de los casos anteriores. Los conjuntos de muestras se encuentran totalmente solapados y no es posible una separación limpia o una regla simple que permita visualizar los datos correctamente.

Se presume lo sucedido en la Figura 4-5 porque la señal de la energía diamagnética no es una característica importante para discernir entre la clase disruptiva y la safe. Es por esto que para trabajos futuros se descarta completamente y se exploran nuevas alternativas con características más importantes.

A continuación se muestran los resultados obtenidos tras la clasificación en tiempo real de cada una de las descargas tanto disruptivas como safe de la señal “Energía Diamagnética”.

- ❖ Regla simple
 - VA: 0%
 - TD: 0%
 - PA: 100%
 - SR: 100%
 - FP: 100%
 - Promedio WT: 10,67[s]
 - Desv. Estándar WT: 4,25[s]
- ❖ Adaboost
 - VA: 4,29%
 - TD: 0%
 - PA: 95,71%
 - SR: 100%
 - FP: 98,02%
 - Promedio WT: 10,39[s]
 - Desv. Estándar WT: 4,64[s]

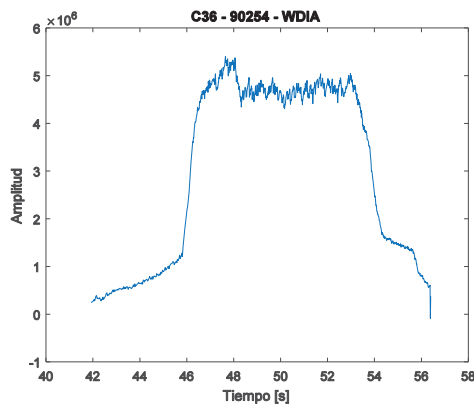


Figura 4-4. Descarga disruptiva Energía diamagnética

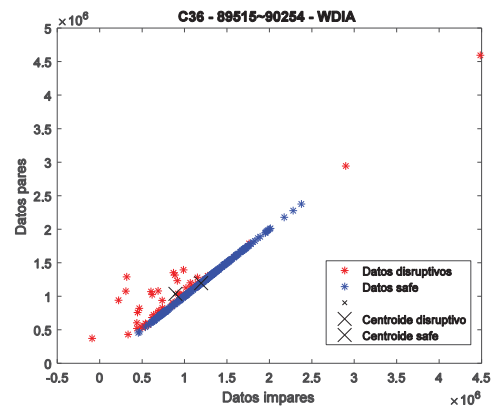


Figura 4-5. Conjunto de muestras Energía diamagnética

En este caso por ningún motivo se lograron buenos resultados, ni con las tasas de acierto ni con los tiempos asociados a la clasificación por lo que no se justifica la utilización de esta señal.

4.2 Experimento con ventanas temporales

El análisis de las ventanas temporales ha sido aquel que mejores resultados ha dado. Consiste en etiquetar cada ventana (ver sección 3.6) con su respectivo vector de características asociado. De esta forma el clasificador tendrá información suficiente para determinar distintas relaciones entre todos los datos adquiridos.

Como ha sido la tendencia a lo largo de este trabajo, nuevamente la selección de los datos ha sido muy importante para lograr los resultados propuestos. Es por eso que en las secciones siguientes se propondrán diversos métodos de selección de datos, dando a conocer todos los pasos intermedios necesarios para conseguir el objetivo.

4.2.1 Selección de datos disruptivos

Para seleccionar los datos disruptivos de las diferentes descargas se hace de una forma bastante sencilla. Simplemente se toma el último dato de la descarga (que dado su procesamiento corresponde al instante disruptivo) y dicho dato se ingresa al clasificador. De esa forma se van concatenando todas las descargas en un solo vector y luego se ingresan al clasificador para ser entrenado. Se propuso de esta forma pues así se logra capturar solo el comportamiento disruptivo de la descarga y apartarlo de la tendencia inicial con características de una descarga safe.

En la Figura 4-6 se muestra ilustrativamente como una característica es extraída de una descarga disruptiva Mode Lock e ingresa al vector que pasará a ser el entrenamiento para el clasificador.

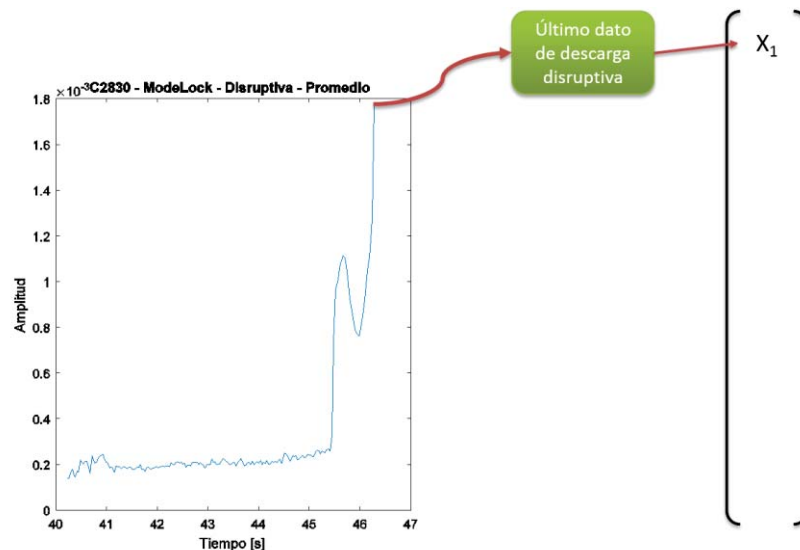


Figura 4-6. Selección de datos disruptivos

4.2.2 Metodo de selección de datos safe aleatorios

Una de las formas de seleccionar los datos safe antes de que ingresen al clasificador es mediante una semilla generadora (para replicabilidad). En este caso en particular fueron seleccionado tres datos safe aleatorios de la descarga disruptiva y dichos datos ingresaron a un vector. Se prefirió

este método porque, de manera empírica, el promediar la descarga completa producía pésimos resultados.

De esa manera se pueden obtener distintas características provenientes de cada una de las descargas safe. En la Figura 4-7 se muestra como se extraen un total de tres características de una descarga safe Mode Lock e ingresan al vector que posteriormente se entrenará.

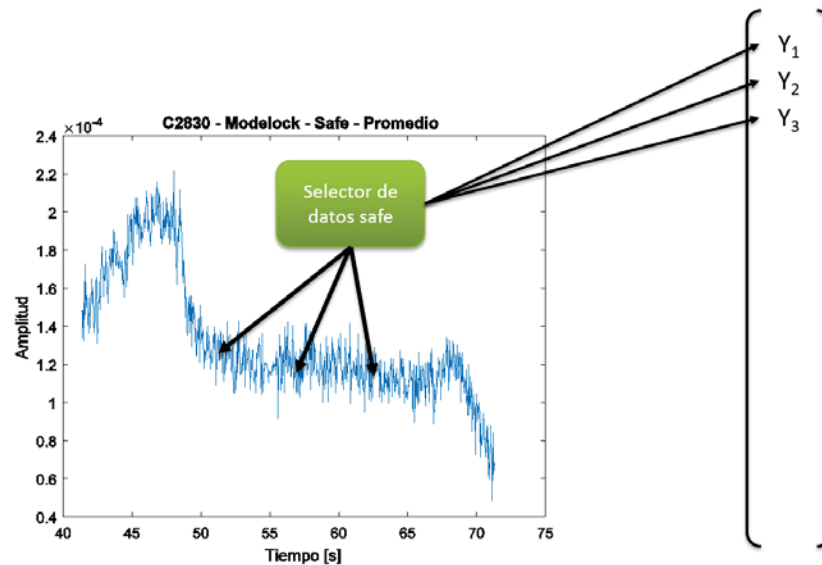


Figura 4-7. Selección de datos safe

4.2.3 Método de selección de datos safe centrales

Este método de selección busca ubicar los datos centrales de la descarga safe. Esto se hace porque tanto al inicio como al final de la descarga, esta presenta comportamientos algo erráticos por efecto de que está iniciando o acabando la descarga.

La cantidad de datos ingresados al vector depende exclusivamente del tamaño de la descarga. Siempre se busca que al vector ingresen la mitad (o un cuarto) de los datos safe. En la Figura 4-8 se observa como ingresan al vector de entrenamiento toda una porción central de la descarga safe.

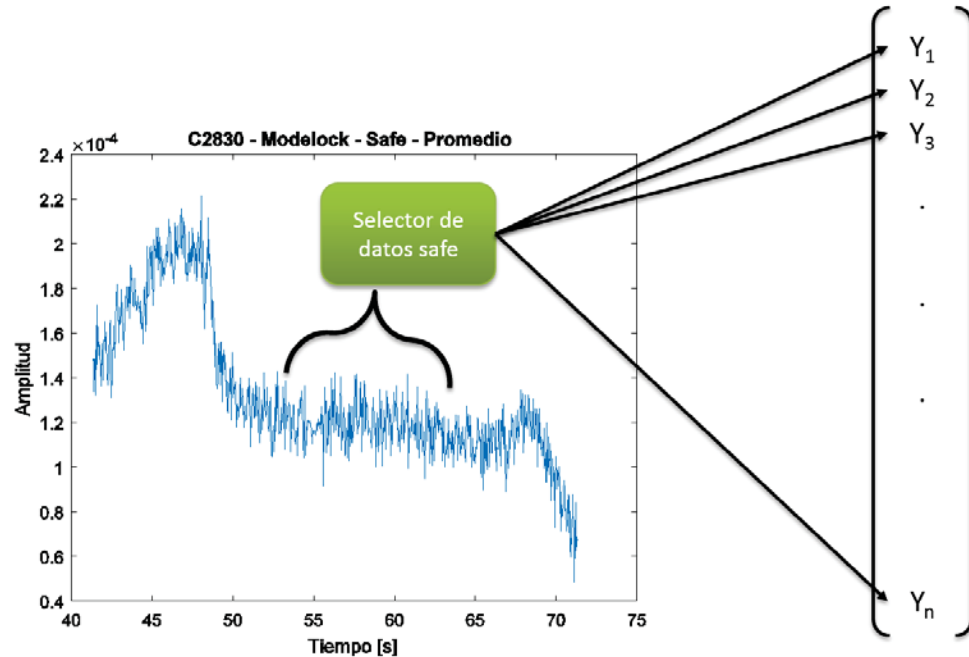


Figura 4-8. Selección de datos safe centrales

4.2.4 Resultados obtenidos

En esta sección se presentarán los resultados obtenidos para el mejor clasificador obtenido. Estos resultados se dividen en tres partes: primera etapa, segunda etapa y clasificador final en cascada.

Para la primera etapa se utilizó el mismo algoritmo Adaboost pero con árboles un poco más complejos, en este caso se utilizó tan solo una regla y dos Split máximo. Esto permitió que la tasa de acierto aumentara bastante, sin embargo la tasa de falsos positivos también aumentó.

A continuación se presentará el árbol de decisión antes mencionado en la Figura 4-9.




Figura 4-9. Árbol de decisión primera etapa

Cómo se trata de una sola regla, es posible mostrar explícitamente el árbol de decisión. La regla x1 y x7 son aquellas que el algoritmo detectó como más importantes y corresponden al promedio de la señal Mode Lock y la pendiente de la señal Mode Lock.

- ❖ Resultados primera etapa:
 - VA: 68,75%
 - TD: 10,42%
 - PA: 18,75%
 - SR: 97,92%
 - FP: 28,16%
 - Promedio WT: 2,56[s]
 - Desv. Estándar WT: 5,98[s]

La primera etapa no cumple con todos los criterios esperados, sin embargo se acercan bastante y sirven para realizar una segunda etapa. La segunda etapa consiste en entrenar con aquellos datos que fueron mal clasificados en la primera etapa. En esta etapa se utilizaron 35 reglas con 5 splits por árbol

- ❖ Resultados segunda etapa:
 - VA: 81,25%
 - TD: 4,17%
 - PA: 10,42%
 - SR: 95,83%
 - FP: 28,16%
 - Promedio WT: 514,5[ms]
 - Desv. Estándar WT: 580,7[ms]

Con ambos modelos finalizados, se procede al test general. Para el test general se apartó el 40% de los datos totales. Con dichos datos se procede a realizar los pasos para hacer un test de clasificadores en cascada.

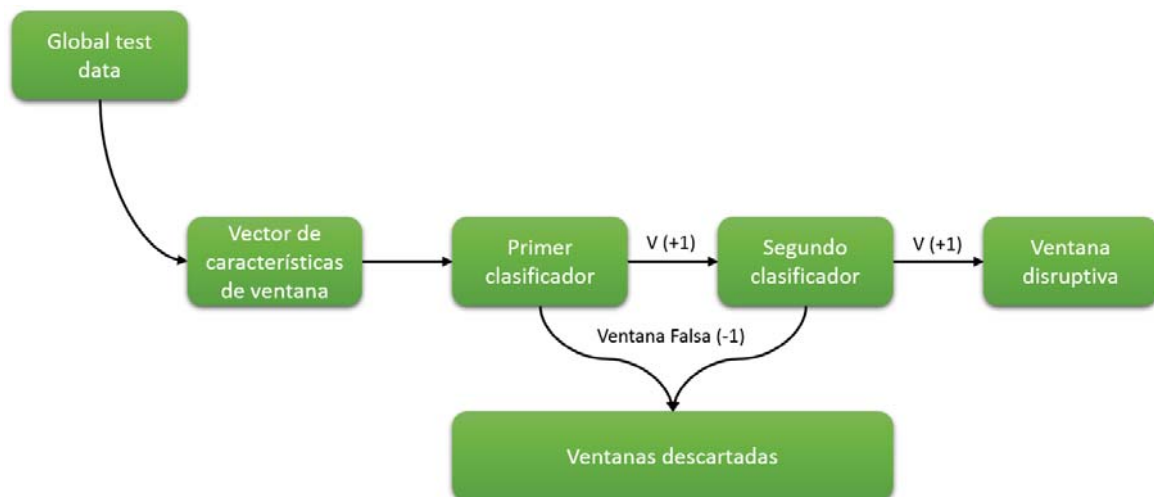


Figura 4-10. Test de clasificador en cascada

Como se puede observar en la Figura 4-10, el test del clasificador en cascada es un poco más complejo que los observados anteriormente. Este empieza cuando se extrae el vector de características de alguna ventana proveniente de alguna descarga del conjunto de test global que se apartó en un principio. Una vez obtenido dicho vector, se evalúa su salida en el primer clasificador, si resulta que el resultado es -1 o negativo, quiere decir que dicha ventana es safe, dicho esto, se continúa con la siguiente ventana. En caso contrario, si ocurre que la salida del clasificador fuese +1 o positiva, entonces deberá entrar al segundo clasificador para corroborar que esta predicción fue correcta. En este punto pueden ocurrir dos opciones: i) Que la salida del segundo clasificador sea -1, si esto ocurre, se descarta la ventana y se continúa con la siguiente. ii) Que la salida del segundo clasificador sea +1, si esto ocurre, se concluye que la ventana es disruptiva y se detiene la descarga [16]. Una vez esto suceda, se procede a evaluar la siguiente descarga pues si el sistema estuviese implementado en tiempo real, debería apagarse el reactor.

A continuación se presentan los resultados obtenidos tras la ejecución de un test con este clasificador.

- ❖ Resultados clasificador en cascada:
 - VA: 62,5%
 - TD: 16,25%
 - PA: 11,25%
 - SR: 90%
 - FP: 4,41%
 - Promedio WT: 994,8[ms]
 - Desv. Estándar WT: 3148[ms]

4.2.5 Resultados obtenidos sin Mode Lock

Para la obtención de estos resultados no fue utilizada la señal Mode Lock. Sin embargo las tasas no fueron tan buenas como las esperadas y se descartaron para seguir avanzando en las etapas posteriores. Cabe destacar que la ventaja de no utilizar la señal Mode Lock radica en el tiempo que ocurre antes de que se active la alarma de disrupción, dicho tiempo permitiría al operador tomar acciones para evitar la disrupción. Este modelo fue realizado con 4 splits y 6 reglas.

- ❖ Resultados primera etapa:
 - VA: 45,83%
 - TD: 4,17%
 - PA: 45,83%
 - SR: 95,83%
 - FP: 58,37%
 - Promedio WT: 2,06[s]
 - Desv. Estándar WT: 3,14[s]

Discusión y conclusiones

El uso de las técnicas de aprendizaje automático y extracción de características puede ser el único camino viable al pleno control, tanto de evitación como de mitigación para las interrupciones de fusión nuclear. Si bien existen numerosos estudios pasados y existirán más aún futuros, se ha probado que los predictores pueden seguir mejorando y quizás alcanzar el ansiado 100% de SR.

Cabe destacar que Adaboost permite tener conocimiento pleno de las características que son importantes para el predictor. Una ventaja inalcanzable para métodos de redes neuronales o SVM. De hecho algunos trabajan con capas ocultas, lo que hace imposible conocer qué tipo de procesos internos ocurren. Lo anterior incluso es perjudicial cuando se requiere inferir la respuesta del modelo con anterioridad, observando cómo se van comportando las variables a lo largo del tiempo.

La correcta división de datos y uso del clasificador en cascada es crucial para evitar posibles errores, uno de ellos es la falta de datos en algún punto. Si bien Adaboost es bastante resistente al sobre-entrenamiento, el modelo requiere una cantidad de datos considerable para lograr buenos resultados en las predicciones.

Si bien en la primera etapa de experimentación no se lograron los resultados esperados, es un pequeño avance en la creación de reglas simples para clasificar eventos disruptivos. La naturaleza de la búsqueda de reglas simples es un gran desafío pues los fenómenos de esta magnitud son particularmente complejos y con una cantidad virtualmente infinita de variables.

El análisis de centroides está orientado a las técnicas de mitigación. Un Warning Time demasiado corto con una desviación estándar relativamente grande ocasiona que las interrupciones se detecten casi en el momento en que están ocurriendo, cuando ocurre eso, genera desconfianza de las respuestas que está entregando el modelo, pues quizás en alguna oportunidad prediga hasta incluso 1 segundo después de que ocurra la interrupción, escenario perjudicial desde cualquier punto de vista.

El nuevo enfoque de los centroides ha producido un cambio positivo en las predicciones con modelos simples, los parámetros mejoraron bastante. Se propone la idea que es así porque se va analizando la señal de adelante hacia atrás por lo tanto el WT debería crecer en consecuencia.

Es importante destacar que Adaboost representa un buen modelo predictivo, sin embargo no hay forma posible de controlar los tiempos de predicción directamente. Es por eso que conviene el análisis de ventana temporal, pues se ingresan los datos en cuyos instantes se requiere que Adaboost inicie una alarma de interrupción inminente.

Los resultados de la señal Mode Lock son de especial interés para iniciar un clasificador en cascada, dicha señal permite resultados bastante altos en términos de tasas de acierto, obviamente sacrificando su implementación en tiempo real dado Warning Times de valores bajos.

Al igual que en la mayoría de las señales, las bolométricas no obtiene muy buenos resultados y el pre-procesamiento debe ser exhaustivo para su correcto funcionamiento. Esto último es algo indeseado pues la tónica es generar reglas simples con modelos sencillos que exijan poco tiempo de procesamiento y además que los operadores de los dispositivos de fusión nuclear puedan analizar fácilmente para tomar decisiones con antelación suficiente.

Generar un modelo simple y con un buen desempeño parece una tarea bastante difícil, sin embargo se lograron algunas aproximaciones que se podrían considerar simple. La clave del desempeño estuvo en la capacidad de fusionar distintas naturalezas de clasificadores; señales temporales con imágenes, a simple vista pareciese no tener mucho sentido pero los resultados demuestran que es perfectamente viable.

Ocupar un clasificador en cascada mejora notoriamente los resultados, pues se enfoca en mejorar lo previamente entrenado, disminuyendo la tasa de falsos positivos y aumentando la de verdaderos positivos. Una desventaja es que requiere una gran cantidad de datos pues son necesarias muchas divisiones entre cada etapa.

Actualmente el mayor problema de los modelos es la dificultad de detectar las descargas safe y esto es porque no se puede correr el riesgo que la descarga siga en ejecución si el sistema ya considera que la descarga es disruptiva. Lo anterior genera una fuerte disyuntiva entre el modelo teórico y sus consecuencias experimentales

Uno de los principales inconvenientes que se presentó transversalmente en las distintas líneas y enfoques del trabajo fue la selección de los datos tanto de entrenamiento como de test. Elegir los datos convenientemente tendrá consecuencias directas sobre los resultados por lo que es mejor optar por un método complejo de selección de datos en conjunto con un clasificador sencillo.

Bibliografía

- [1] Y. Freund y R. E. Schapire, «A Short Introduction to Boosting,» *Journal of Japanese Society for Artificial Intelligence*, vol. 5, nº 14, pp. 771-780, 1999.
- [2] C. Mondial, D. E. L. É. Gie, Y. D. Kim, L. Birnbaum, G. Ward y C. Frei, «Recursos energéticos globales,» *World Energy Counc*, 2013.
- [3] BP, «BP Statistical Review of World Energy 2016,» 2016. [En línea]. Available: http://www.bp.com/es_es/spain/prensa/notas-de-prensa/2016/bp-statistical-review-worldenergy-2016.html. [Último acceso: 13 11 2017].
- [4] M. Lehnen, K. Aleynikova, P. Aleynikov, D. Campbell, P. Drewelow, N. Eidietis, Y. Gasparyan, R. Granetz, Y. Gribov, N. Hartmann, E. Hollmann, V. Izzo, S. Jachmich, S.-H. Kim, M. Kocan, H. Koslowski, D. Kovalenko y U. Kruezi, «Disruptions in ITER and Strategies for their Control and Mitigation,» *Journal of Nuclear Materials*, vol. 463, pp. 39-48, 2015.
- [5] A. Rowcliffe, L. Garrison, Y. Yamamoto, L. Tan y Y. Katoh, «Materials challenges for the fusion nuclear science facility,» *Fusion Engineering and Design*, p. 12, 2017.
- [6] ITER, «ITER,» 14 4 2008. [En línea]. Available: https://www.iter.org/doc/www/content/com/Lists/Stories/Attachments/680/ITER_W7X.pdf. [Último acceso: 13 11 2017].
- [7] C. M. Bishop, *Neural Networks for Patter Recognition*, Oxford: Clarendon Press, 1995.
- [8] C. Cortes y V. Vapnik, «Support-vector networks,» *Machine Learning*, vol. 3, nº 20, pp. 273-297, 1995.
- [9] J. Vega, «Advanced Disruption Predictor Based on the Locked Mode signal: Application to JET,» de *First Eps Conference on Plasma Diagnostics*, Italia, 2015.

- [10 G. J. van Rooij, «Characterization of Tungsten Sputtering in the JET divertor,» de *Proceeding of the 24th IAEA Fusion Energy Conference*, US, 2012.
- [11 L. C. Ingesson, «Limitations to Total Radiated Power Determination in Divertor Tokamaks,» de *JET Joint Undertaking*, Oxfordshire, 1999.
- [12 K. F. Mast y H. Krause, «Bolometric diagnostics in JET,» United Kingdom, 1998.
- [13 A. Kirk, A. J. Thornton, J. R. Harrison, F. Militello y N. R. Walkden, «L-mode filament characteristics on MAST as a function of plasma current measured using visible imaging,» *EUROFUSION WPMST1-PR*, nº 14680, 2016.
- [14 C. Leys, C. Ley, O. Klein, P. Bernard y L. Licata, «Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median,» *Journal of Experimental Social Psychology*, vol. 49, nº 4, pp. 764-766, 2013.
- [15 P. Alvalde San Miguel, *Electrotecnia: Instalaciones eléctricas y automáticas*, Madrid: Paraninfo, 2014.
- [16 P. Viola y M. J. Jones, «Robust Real-Time Face Detection,» *International Journal of Computer Vision*, vol. 57, nº 2, pp. 137-154, 2004.