

# DETECCIÓN AUTOMÁTICA DE PLANOS DE RUEDA DE FERROCARRIL MEDIANTE TRATAMIENTO DIGITAL DE IMÁGENES EMPLEANDO LA TRANSFORMADA DE HILBERT

**Enrique Hernández Hernández <sup>(a)</sup>, Rafael Trallero Vela<sup>(b)</sup>**

(a) Ingeniero Industrial. Departamento de Mecánica  
Profesor de Grado en Ingeniería Mecatrónica  
Escuela Politécnica Universitaria de La Almunia  
Universidad de Zaragoza.

Teléfono: 976 600 525, e-mail: [enhernan@unizar.es](mailto:enhernan@unizar.es)

(b) Doctor Ingeniero Aeronáutico. Centro de Ensayo de Programas Aeroespaciales  
Instituto Nacional de Técnica Aeroespacial 'Esteban Terradas'.  
Profesor de Grado en Ingeniería Aeroespacial  
Escuela Politécnica Superior, Universidad Alfonso X el Sabio.  
Teléfono: 918 105 793, e-mail: [rtralvel@uax.es](mailto:rtralvel@uax.es)

## RESUMEN:

El presente artículo muestra una técnica basada en el tratamiento digital de imágenes, para diagnosticar planos de rueda de ferrocarril, para ello: se han extraído todos los picos de la señal; se ha hecho uso del concepto de señal analítica cuya parte real es la propia señal, es decir cada pico de la señal adquirida, y su parte imaginaria es la transformada de Hilbert de la señal original; se ha efectuado la representación de Lissajous de la señal analítica, de esa representación se ha obtenido una imagen a la que se aplican técnicas para la extracción de características de forma y contenido de regiones de píxeles; la selección de estas se ha llevado a cabo mediante búsqueda heurística empleando una función de evaluación basada en matrices de dispersión y su clasificación se ha realizado mediante aprendizaje supervisado empleando una Máquina de Vectores Soporte (MVS), utilizando la validación cruzada para la obtención de sus parámetros óptimos.

**PALABRAS CLAVE:** Planos de rueda, Transformada de Hilbert, Tratamiento digital de imágenes, Máquinas de Vectores Soporte.

*ABSTRACT: This article demonstrates a technique based on digital imaging to diagnose railway wheel flats, then: have extracted all the peaks of the signal; It has made use of the concept of analytic signal whose real part is the signal itself, ie each acquired signal peak, and its imaginary part is the Hilbert transform of the original signal; has made Lissajous representation of analytical signal, this representation has been obtained image that apply techniques for extracting features of form and content of regions of pixels; the selection of these has*

*been carried out by heuristic search using an evaluation function based on scattering matrices and classification was performed using supervised learning using a Support Vector Machine (SVM ) using cross validation to obtain their optimal parameters .*

*KEY-WORDS: Wheel flats, Hilbert Transform , Digital image processing , Support Vector Machine.*

**SUMARIO:** 1. Introducción 2. Métodos de supervisión 3. Preprocesado de la señal 4. Extracción de características 5. Selección de características 6. Clasificación 7. Conclusiones 8. Bibliografía

*SUMMARY: 1. Introduction. 2. Methods of supervision. 3. Signal Preprocessing . 4. Feature extraction . 5. Selection of features. 6. Classification . 7. Conclusions . 8. Bibliography*

## **1. Introducción**

En el mundo ferroviario se consideran las ruedas como el factor más importante para la seguridad, siendo el descarrilamiento el riesgo más grande al que se enfrenta un tren en circulación. La Oficina de Análisis de Seguridad de la Administración Federal de Ferrocarriles FRA (*Federal Railroad Administration*) de los Estados Unidos, realizó un análisis sobre los daños ocurridos en las diferentes partes mecánicas que habían provocado accidentes ferroviarios entre los años 2004 y 2007. Este estudio revelaba, que el conjunto formado por ruedas, ejes y rodamientos; supone un 44,7% de contribución sobre el total de accidentes causados (Yenn et al., 2010).

Las ruedas están sometidas a deslizamientos y a cargas térmicas importantes. Es por esto que toman especial relevancia, todos los aspectos que intervienen en la dinámica rueda-carril. Fenómenos tales como el rozamiento, el desgaste o la adhesión; pueden producir fallos más o menos severos, pérdidas energéticas, costes de mantenimiento y contaminación acústica (Tourrade, 1985).

Los planos de rueda son fallos que se producen en las ruedas de los vehículos por desgaste del material, perdiendo en algún punto la rueda su curvatura y apareciendo una superficie plana. Normalmente aparecen cuando se bloquea la rueda como consecuencia de un frenado del tren, como resultado de un freno defectuoso o mal ajustado, o una fuerza de frenado que excede temporalmente a la fuerza de fricción del conjunto rueda-raíl. Una segunda razón por la que se generan los planos de rueda es por una reducción de las fuerzas locales de adhesión rueda-raíl, que le lleva a deslizar. Esto último puede suceder por la presencia en el raíl de nieve, lubricantes o de hojas, sobre todo en otoño (Kloow y Jenstav, 2006; Verheijen et al., 2007). El efecto abrasivo por el hecho de patinar causa un alto desgaste de la superficie de rodadura (un plano de rueda), con longitudes que van típicamente de 20 a más de 100 mm.

En un tren circulando a velocidades entre 30 y 50 km/h, la presencia de planos en las ruedas, hace que estas pierdan el contacto con el carril momentáneamente, y cuando nuevamente se

encuentran, se produce un impacto varias veces superior a su carga estática, lo que puede provocar daños tales como:

- Calentamiento o rotura de ejes y cajas de grasa.
- Daños en los rodamientos.
- Grietas que penetran en las ruedas.
- Rotura de raíles y traviesas.

Además de provocar un aumento del consumo energético, y un nivel de vibración excesivo que produce ruido molesto.

## 2. Métodos de Supervisión

Los planos de rueda y la interacción rueda-raíl han sido objeto de una intensa investigación desde mediados del siglo pasado. Se han realizado modelos matemáticos y ensayos, basados en la supervisión de su estado mediante tecnologías conducidas por datos, con la finalidad de analizar la firma del fallo y clasificarla. El objetivo fundamental, es el de poder realizar una detección temprana, sin tener necesidad de desmontarlas para efectuar su inspección, por el alto coste que ello conlleva.

La dinámica de un vehículo de ferrocarril representa un equilibrio en la interacción de ruedas, fuerzas de suspensión y fuerzas de inercia. Los ferrocarriles modernos utilizan sistemas de supervisión sofisticados para prever su comportamiento total dinámico, e identificar condiciones críticas inminentes durante su operativa normal. Para ello, técnicas tales como: el filtrado avanzado, la identificación de sistemas y el análisis de señales; son métodos sólidos, para detectar fallos que provocarán averías con el tiempo (Ward et al., 2011). Estos métodos, requieren de modelos matemáticos del sistema menos complicados, y pueden vencer potenciales dificultades asociadas con variaciones de parámetros y no linealidades.

A menudo la medida directa de parámetros es difícil de conseguir, debido a los altos costes que conlleva o la falta de tecnología adecuada. En estos casos las técnicas de supervisión de la condición son las más apropiadas por: su buen comportamiento frente a sistemas fuertemente no lineales, su robustez, sensibilidad a las perturbaciones y representación computacional. La aplicación práctica de la supervisión de la condición, en la dinámica de trenes, se consigue mediante el empleo de sensores en los raíles o en los vehículos. Habitualmente los sensores en pista se utilizan para la supervisión de las ruedas, mientras que los conectados en los vehículos, se emplean para monitorizar la salud estructural de la vía (Ngigi et al., 2012).

A la hora de efectuar el análisis de señales provenientes del sistema de detección el dominio temporal ha demostrado ser el más eficaz, a la hora de detectar defectos tipo plano en la superficie de rodadura de las ruedas del tren (Jordi et al., 2010; y Zhang et al., 2010); ya que

se necesita saber cuándo y dónde se produce el fallo, para la identificación precisa del vehículo y rueda. Para obtener el instante exacto de paso de las ruedas por el punto de medida, se utiliza el registro del esfuerzo cortante al que está sometido el carril al paso de cada rueda, lo más eficiente es mediante el uso de sensores extensiométricos.

### **3. Preprocesado de la señal**

La finalidad del procesado, será definir un conjunto de operaciones sobre una determinada variable, de forma que sea posible discriminar con facilidad, las firmas de determinados defectos.

Los métodos automáticos de diagnóstico, de fallos aplicables, se pueden clasificar, en función del proceso de conocimiento requerido a priori, en dos categorías principales: métodos basados en modelos y sistemas de diagnóstico basados en datos.

El método empleado para la detección automática de los fallos en ruedas, está conducido por datos por dos motivos fundamentales: por un lado, la dificultad de modelar adecuadamente el comportamiento del sistema, ya que no se dispone de señales perfectamente calibradas ni se conoce el modelo de interacción rueda-vía, en este caso concreto; y por otro lado, por disponer de suficiente cantidad de señales para poder realizar el tipo de tratamiento de interés.

El procedimiento utilizado en técnicas de mantenimiento inteligente se suele descomponer en las siguientes partes: preprocesado, extracción de características, selección de características, clasificación de características y pronóstico. El presente apartado se centra en la primera etapa de preprocesado.

En primer lugar es necesario hacer una breve referencia al marco experimental. La adquisición de las señales se llevó a cabo monitorizando un rail, modelo UIC 54 con fijaciones DFF sobre placa, del metro de Bilbao. El equipo empleado fue el sistema de adquisición CompacRio de National Instrument, empleando como sensor una galga extensiométrica, entre otras, en posición vertical, con un espacio de detección de 3,2 m. El software empleado es Matlab en su versión R2012.

La experimentación se realizó entre el 30 de mayo y el 4 de junio de 2013 y un intervalo de velocidades entre los 53-58 Km/h. El modelo de suburbano fue una unidad UT 513 fabricada por CAF en 1995, que consta de 5 coches de composición M-M-M-M-M, es decir con 10 bogies motrices, con un total de 20 ejes, siendo las distancias entre ellos, la que va de eje a eje, de un mismo bogie 2,2 m y entre bogies contiguos de 4,34 m. Las ruedas son del tipo ensambladas, muy utilizadas en metros y tranvías por su insonorización, de diámetro 840 mm. Se sabía de antemano que este tren presentaba un plano de rueda en su eje vigésimo octavo.

En la Figura 3.1 se muestra una de las señales obtenidas, en la que se aprecia un tren que está compuesto de cinco coches. Como cada coche tiene cuatro ruedas, dos del bogie delantero y dos del trasero, en total aparecen los veinte picos correspondientes a las veinte ruedas.




Figura 3.1. Señales obtenidas.

Una vez la señal ha pasado de una forma continua a discreta, se han suprimido los 50 Hz de la red modificando la FFT y calculando su transformada inversa, lo que ha eliminado sensiblemente rizado de la señal.

Para eliminar el ruido de alta frecuencia se ha empleado un filtro de tipo IIR, recursivo y por lo tanto más eficiente computacionalmente que los de tipo FIR, en concreto el de Butterworth de desfase cero, al objeto de que los picos no cambien de posición, pues produce una respuesta muy plana en la banda de paso. Se ha observado que la frecuencia de fallo es inferior a 1 KHz, por lo que se han utilizado dos filtros uno de orden 12 con un ancho de banda de 1 KHz y otro con ancho de banda de 400 Hz, en ambos casos los resultados han sido satisfactorios. La figura 3.2 se muestra un detalle de pico con fallo y su precedente una vez filtrada la señal.




Figura 3.2 Detalle del pico con fallo y su precedente

Con la finalidad de poder detectar los fallos se han buscado vibraciones locales atípicas, localizándose como estaba previsto en el eje vigésimo octavo afectado por el plano de rueda, y observando la banda de bajas frecuencias, que se muestra en la Figura 3.3, se puede comprobar que el pico próximo a 200 H, correspondiente a la frecuencia generada por las ruedas al pasar por el sensor, tiene una amplitud sensiblemente mayor en el pico que procede de la rueda con fallo, lo que se puede comprobar en el dominio del tiempo, así como el efecto de amortiguación producido por la reactancia de la vía.




Figura 3.3 Comparación a escala de los espectros de la señal con y sin fallo.

## 4. Extracción de características

### 4.1 Extracción de picos

Al objeto de realizar un análisis exhaustivo se han extraído todos los picos de las señales obtenidas para comparar el comportamiento de las distintas ruedas. El procedimiento de extracción ha sido complejo por la gran cantidad de circunstancias que se dan en las señales. En la figura 4.1 se muestra la señal una vez filtrada a 62,5 KHz, con un filtro de Butterworth de orden 25, y eliminadas 1200 muestras para evitar los efectos iniciales y finales, 600 por cada lado, con la finalidad de conseguir mayor exactitud en la identificación de los picos. El análisis de picos ha determinado el comportamiento en el dominio del tiempo del impacto debido al fallo.




Figura 4.1 Identificación de los picos, previa a su extracción.

### 4.2 Representación de las señales

Una vez se han extraído los picos de la señal, con ellos se ha construido una señal analítica definida en el plano complejo empleando las características que aporta la transformada de Hilbert. El caso más interesante, en este caso, es aquél en que dada una función real  $x(t)$ , se asocia como parte imaginaria a su transformada de Hilbert  $\hat{x}(t)$ .

$$m(t) = x(t) + j\hat{x}(t) = a(t)e^{j\varphi(t)} \quad (\text{Ec. 4.1})$$

En donde:

$$a(t) = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (\text{Ec. 4.2})$$

Y

$$\varphi(t) = \text{arc tg } \frac{\hat{x}(t)}{x(t)} \quad (\text{Ec. 4.3})$$

De esta forma, es posible ver la señal como un vector giratorio con una amplitud instantánea  $a(t)$  y una fase instantánea  $\varphi(t)$  en el dominio del tiempo. A la amplitud instantánea se le denomina «Envolvente de la señal».

En señales de potencia media finita, el cuadrado de la envolvente da una expresión de la potencia instantánea. Por tanto, la transformada de Hilbert proporciona un método para determinar la frecuencia instantánea y la potencia instantánea de una señal.

De esas expresiones se llega a:

$$x(t) = a(t) \cos[\varphi(t)] \quad (\text{Ec. 4.4})$$

$$\hat{x}(t) = a(t) \text{sen}[\varphi(t)] \quad (\text{Ec. 4.5})$$

Esto permite crear una función compleja que se denomina «Señal Analítica Fuerte». La señal analítica fuerte se puede escribir en forma módulo argumental. El módulo, bajo ciertas condiciones, es la envolvente de la señal; la derivada de la fase se puede identificar con la frecuencia instantánea. No es difícil comprobar que una función y su transformada de Hilbert son ortogonales. Además ambas tienen la misma energía.

Se ha analizado una señal que representa los picos que se producen en el sensor al paso del tren. Para ello se ha utilizado una señal gaussiana más bien estrecha, en la que se ha tomado valor medio uno (el pico está centrado en  $t=1$  segundos y sigma igual a 1,2). En la figura 4.2 se representan la señal gaussiana y su transformada de Hilbert.

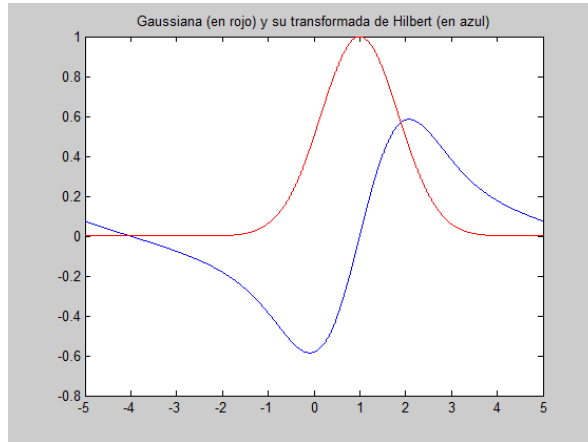


Figura. 4.2 Señal gaussiana (rojo) y transformada de Hilbert de la señal Gaussiana

En la Figura 4.3 se muestra la parte real e imaginaria de la señal analítica de un pico proveniente de la señal adquirida al paso del ferrocarril, construida a partir de la señal obtenida de la etapa de preprocesado como parte real y su transformada de Hilbert como imaginaria.




Figura 4.3. a) Parte real y b) parte imaginaria, de la señal analítica de un pico de la señal.

Obsérvese la similitud con figuras mostradas en la figura 4.3, obtenidas a partir de un pico de la señal real, con las de la figura 4.2

En la Figura 4.4 se muestra una señal gaussiana con oscilaciones locales superpuestas. Para ver su efecto se ha elegido una frecuencia para las oscilaciones locales que da lugar a tres oscilaciones locales en el flanco de subida de la señal gaussiana. A su vez, la amplitud se ha tomado para que se aprecien las oscilaciones locales de forma significativa. Se ha

representado en el plano complejo la señal analítica correspondiente a la señal gaussiana con las oscilaciones locales anteriormente comentadas.

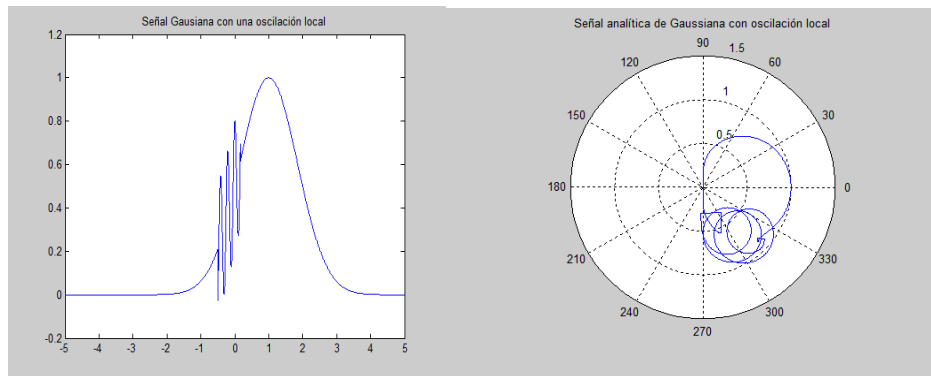


Figura 4.4. Señal gaussiana con tres oscilaciones y su representación en el plano complejo.

En la figura 4.5, se muestra la misma señal y su representación en el plano complejo, pero con ruido añadido. En ella se aprecia que los tres círculos procedentes de los tres períodos de las oscilaciones locales, que aparecían en la señal sin ruido desaparecen, y en esa zona, vemos que se encuentra una nube de puntos sobre una región del plano que tiene forma de corona circular y que está ubicada donde estaban ubicados los tres círculos. Por tanto, vemos que el ruido implica sustituir una circunferencia por un conjunto de puntos ubicados sobre una corona circular.

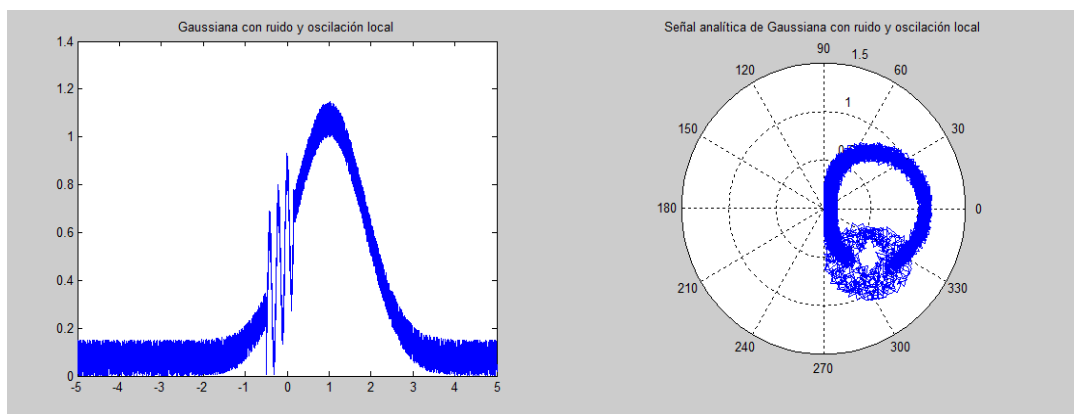


Figura 4.5. Señal gaussiana añadiéndole ruido

Las imágenes obtenidas a partir de la señal adquirida al paso del ferrocarril, una vez obtenida la señal analítica y su representación mediante curva de Lissajous, se muestran en la Figura 4.6 para: a) un pico sin fallo y b) otro con fallo. Debido a las oscilaciones locales que provoca el fallo, se generan nubes de puntos, su dispersión es mayor cuanto mayor sea la oscilación debida al fallo.




Figura 4.6. Imágenes obtenidas de: a) un pico con fallo y b) otro sin fallo.

Las imágenes han sido previamente binarizadas. La imagen binaria, es decir reducida solo a dos niveles de intensidad extremos, como son el blanco y negro, resulta muy interesante por los siguientes motivos:

- La efectividad computacional pues se reduce significativamente la representación de la imagen.
- A partir de las imágenes binarias se pueden obtener muy fácilmente las propiedades topológicas y geométricas de los objetos de interés, son simples y muy robustas.

#### 4.3 Obtención de las características a partir de la imagen

El procedimiento más general empleado a la hora de analizar características en imágenes consiste en:

- Efectuar un preprocesamiento para eliminar ruido, suavizar la imagen y dejarla preparada para la etapa siguiente.
- Identificar los distintos objetos de interés de la imagen, identificando sus bordes y contornos.

- Segmentar los objetos empleando la información obtenida en la etapa anterior.

La primera etapa para el análisis de la imagen es la del procesamiento de esta, que tal y como se comentó anteriormente consiste en dejar la imagen preparada para la etapa posterior, lo que ha consistido en una binarización y escalado de la imagen.

Para la obtención de los descriptores de textura de la región de interés, resulta conveniente efectuar un escalado de la imagen, este consiste en reducir agrupando y sumando los valores de la imagen contenidos en cuadrados de dimensión *escala*.

Con el fin de preservar, sobre todo en los picos con fallos, la región interior para poder seguir obteniendo sus características geométricas en una escala inferior, de manera que sea más fácil la comparación de valores, se ha empleado un algoritmo sencillo de elección de umbral automático, propuesto por Otsu (Otsu, 1979).

En la figura 4.7 se muestra el resultado de aplicar esta operación, la matriz está formada por enteros que representan la suma de puntos para cada cuadrado a escala, diferenciados por colores, creándose de esta manera una textura. Obsérvese la diferencia entre la imagen que representa el pico sin fallo de la que contiene un plano.




Figura 4.7 Representación de las texturas de los picos sin y con fallo

La segunda etapa ha sido la de identificación de la región de interés, esto ha permitido la obtención de los descriptores de forma o características geométricas, para ello ha sido necesario realizar una serie de operaciones, que en tratamiento de imágenes se denominan morfológicas, para establecer las regiones de interés.

La imagen binaria obtenida no es válida para extraer las características del área interior ya que no forma un conjunto conexo y por lo tanto no se le puede considerar una región. Para

conseguirlo se utilizan operaciones de morfología matemática sobre conjuntos sobre las imágenes binarias. Se han empleado las siguientes:

Operaciones de *dilatación*, definidas como:

$$X \oplus S = \{p \in E^2: p = x + s, x \in X \text{ y } s \in S\} \quad (\text{E.c. 4.6})$$

Donde  $X$  es la imagen y  $S$  es el elemento estructurante. Los elementos estructurantes bidimensionales consisten fundamentalmente en una matriz de ceros y unos mucho menores que la imagen a procesar, en este caso se ha empleado una matriz de ocho por ocho conteniendo unos formando una imagen que representa un disco.

Operaciones de *erosión*, se trata de la operación opuesta a la dilatación.

$$X \ominus S = \{p \in E^2: p + s \in X \forall s \in S\} \quad (\text{E.c. 4.7})$$

El operador *cierre* o clausura de la imagen, consistente en una dilatación seguida de una erosión.

$$X \bullet S = [(X \oplus S) \ominus S] \quad (\text{E.c. 4.8})$$

Finalmente se ha aplicado el operador *complementaridad* que consiste en intercambiar ceros por unos.

$$\bar{X} = \{p \in E^2: \bar{p} \in X\} \quad (\text{E.c. 4.9})$$

El resultado de aplicar estas operaciones se puede ver en la figura 4.8.

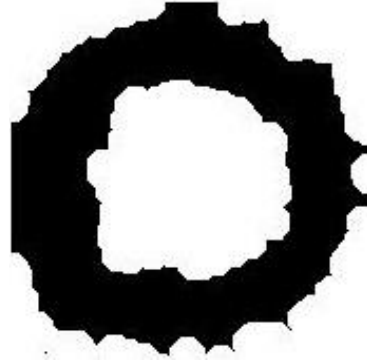


Figura 4.8. Regiones obtenidas a partir de las operaciones morfológicas

La tercera etapa y última es la de segmentación. La región de interés en la imagen es el área circular interna libre de puntos, cuyas características se han obtenido como medidas cuantitativas empleadas para establecer la clasificación entre ruedas con y sin plano. Esta región se ha obtenido sin más que atender a un criterio de proximidad espacial. Para ello se ha procedido al etiquetado de las regiones, de manera que se ha extraído la región interior empleando un algoritmo de búsqueda en profundidad recursivo.

Conceptualmente se trata de a partir de un primer pixel semilla, ir rellenando cada una de las regiones de manera que cada conjunto conexo tenga una numeración distinta y cada pixel dentro de dicho conjunto tenga el mismo (algoritmos flood-fill).

De esta forma se ha etiquetado y extraído la región interior. El resultado se muestra en la figura 4.10, en ella se puede observar la diferencia de tamaño entre el pico con y sin fallo. A partir de aquí se han obtenido las características topológicas de la región.

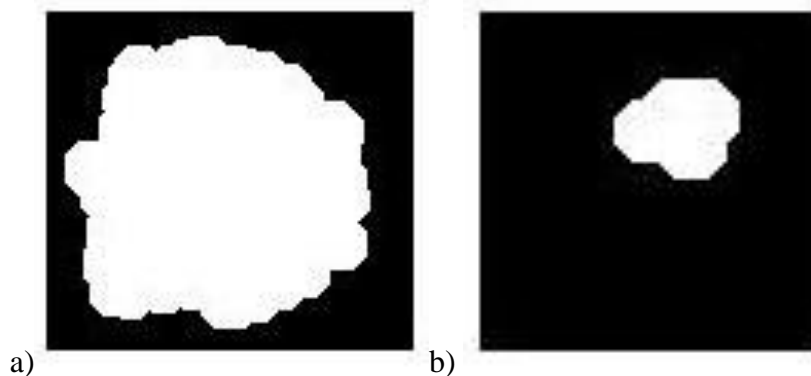


Figura 4.10. Regiones interiores: a) pico sin fallo y b) pico con fallo.

Una vez efectuada la segmentación, el estudio de las propiedades cuantificables de los objetos aporta información relevante que facilita su análisis y la posibilidad de detectar pequeñas variaciones de una forma más precisa. El hecho de trabajar sobre regiones permite obtener información más rica que sobre los píxel del que solo se puede conocer su intensidad y su posición.

A la hora de elegir qué características son las más adecuadas para considerarlas como descriptores de la región objeto de estudio, es deseable que cumplan con algunas propiedades como:

- Unicidad y capacidad discriminante
- Estabilidad e invarianza frente a transformaciones geométricas tales como: rotaciones, traslaciones, cambios de escala y reflexiones.
- Facilidad para la evaluación y abstracción del detalle.

Dichas características como componentes de vectores n-dimensionales conforman descriptores que representan a los patrones que se desea clasificar. Los descriptores empleados forman dos grupos perfectamente diferenciados:

- Descriptores de forma o geométricos de regiones de píxeles, obtenidos a partir de la región interior de la imagen: *área, eje mayor, eje menor, diámetro y perímetro*.
- Descriptores de contenido o textura de regiones de píxeles: *promedio, varianza, desviación, mediana y rango intercuartílico*.

Para ver si los descriptores cumplen con las características deseadas se han aplicado a tres picos extraídos de veinte señales, el primero sin fallo, el segundo inmediatamente anterior al pico con fallo, y el tercero el pico con fallo. En la Tabla 4.1 se muestran los resultados obtenidos de la señal para los tres picos.

<b>Parámetro geométrico</b>	<b>Pico sin fallo</b>	<b>Pico sin fallo anterior al pico con fallo</b>	<b>Pico con fallo</b>
<b>Área:</b>	24	23	4
<b>Eje mayor:</b>	5.9246	6.3111	2.3094
<b>Eje menor:</b>	5.3732	4.8797	2.3094
<b>Diámetro:</b>	5.5279	5.4115	2.2568
<b>Perímetro:</b>	15.6569	15.6569	4

Tabla 4.1. Resultados para tres picos de la señal 's1.bin'.

En la tabla se pueden apreciar los resultados sensiblemente diferentes entre los picos con y sin fallo, siendo muy parecidos en los que no hay fallo. Resultados parecidos se han obtenido para el resto de las señales por lo que las características elegidas se consideran válidas, ya que cumplen con los criterios de unicidad, estabilidad y abstracción.

En la misma línea que en el apartado dedicado a los parámetros geométricos, se han calculado los valores de las características de textura para los tres picos de la señal. Los resultados junto con los histogramas se muestran en la figura 4.11.




Figura 4.11. Histogramas y diagramas de caja y bigotes de: a) pico sin fallo y b) pico con fallo. Los valores atípicos mostrados en los diagramas de caja han sido eliminados para la obtención de los histogramas.

El histograma muestra, en su escala vertical, el número de cuadros a escala con respecto al número de puntos que contienen, representados en el eje horizontal. Como se puede observar en el pico con fallo hay un predominio de bajos valores, lo que indica que los puntos están muy dispersos por toda la imagen, por lo tanto la varianza de valores es sensiblemente menor que en el pico que no contiene fallo. En este los valores en los cuadros a escala son mayores indicando un mayor agrupamiento de puntos en torno al anillo que forman. Los valores de los parámetros estadísticos, seleccionados para los tres picos, se pueden observar en la tabla 4.2.

Parámetro estadístico	Pico sin fallo	Pico sin fallo anterior al pico con fallo	Pico con fallo
<b>Promedio:</b>	79	78.4186	40.6863
<b>Varianza:</b>	2686.9362	2657.9635	248.0996
<b>Sigma:</b>	51.8357	51.5554	15.7512
<b>Mediana:</b>	66	65	38
<b>IQR</b>	76	74	21.5

Tabla 4.2. Valores estadísticos para los tres picos

Nuevamente, como en el caso de los parámetros de forma, se observa que cumplen los requisitos de características, es decir que tienen muy poca variabilidad entre los picos sin fallo y mucha entre estos y los que tienen fallo.

## 5. Selección de características

Se trata de eliminar aquellas características que por ser irrelevantes o redundantes no aportan nada a la clasificación.

Un paso previo ha sido la normalización de los datos de cada una de las características ya que en la mayor parte de las ocasiones no presentan el mismo rango de valores. Así valores de estas más elevados influyen más en la clasificación, independientemente de su relevancia. En este caso se ha empleado una normalización *Softmax*. Se trata de un escalado más o menos lineal, en el rango medio de valores, llegando suavemente de forma exponencial hacia los valores máximos y mínimos.

A partir de aquí se ha efectuado una selección SBS (*sequential backward selection*), empleando una función de evaluación basada en las matrices de dispersión:

$$J_2 = |S_w^{-1}S| \quad (\text{E.c. 4.10})$$

Dónde  $S_w$  es la matriz de dispersión intraclass definida como:

$$S_w = \sum_{i=1}^M P_i S_i \quad (\text{E.c. 4.11})$$

Siendo  $S_i$  la matriz de covarianza, para la clase  $W_i$  y  $P_i$  su probabilidad  
Y la matriz de dispersión interclase:

$$S_B = \sum_{k=1}^M P_i (\bar{x}_i - \bar{x}_0) (\bar{x}_i - \bar{x}_0)^T \quad (\text{E.c. 4.12})$$

$$\bar{x}_0 = \sum_{i=1}^M P_i \bar{x}_i \quad (\text{E.c. 4.13})$$

La matriz de dispersión combinada:

$$S = S_W + S_B \quad (\text{E.c. 4.14})$$

La selección se ha efectuado por una parte sobre las características geométricas y por otro lado sobre las de textura. Se han seleccionado dos por cada grupo, a las cuales se les ha efectuado una nueva selección obteniéndose otras dos, que en este caso han sido la desviación y diámetro, con el fin de poderlas representar en un gráfico.

La figura 5.1 muestra el árbol de búsqueda SBS.  $J_2$  representa la función de evaluación empleada.

Características mixtas: 1=eje menor, 2=diámetro, 3=desviación, 4=mediana




Fig.5.1. Algoritmo SBS para una combinación mixta de características.

El buen comportamiento del algoritmo y la función de evaluación elegidos, se muestra en la Figura 5.2, pues las características seleccionadas aportan una buena separabilidad entre clases. Los datos correspondientes al pico con fallo aparecen en verde y los correspondientes al pico sin fallo en rojo.




Figura 5.2. Separabilidad correspondiente a las características: diámetro y desviación.

## 6. Clasificación

El hecho de poder disponer de muestras de datos etiquetados, ha permitido poder emplear aprendizaje supervisado. De los métodos más comunes utilizados en este tipo de clasificación el más interesante, en este caso, es el empleo del discriminante lineal pues no se tiene conocimiento acerca de la función de densidad de probabilidad de las clases, necesaria para poder emplear otros métodos como por ejemplo los estadísticos.

Una familia de algoritmos, de aprendizaje supervisado, que emplean separadores lineales son las Máquinas de Vectores Soporte MVS, desarrollados por Vapnik (Vapnik, 2000). Puesto que el conjunto de características seleccionado es linealmente separable, se ha aplicado una MVS con clasificación lineal, obteniéndose el resultado que muestra la figura 6.1.




Figura 6.1. Clasificación lineal empleando un clasificador MVS

El conjunto de entrenamiento empleado es de 15 picos sin fallo y 15 con fallo y el conjunto de prueba de cinco señales para cada pico. Dado que el conjunto de entrenamiento puede considerarse pequeño y con la finalidad de que el resultado no dependa de la manera en cómo se han seleccionado los datos de entrenamiento, se ha procedido a efectuar validación cruzada entre los datos de entrenamiento y prueba, con la que se han obtenido los parámetros óptimos de un Kernel de Base Radial aplicado a la MVS, según el método seguido por Hsu (Hsu et al., 2010). El resultado se muestra en la Figura 6.2.

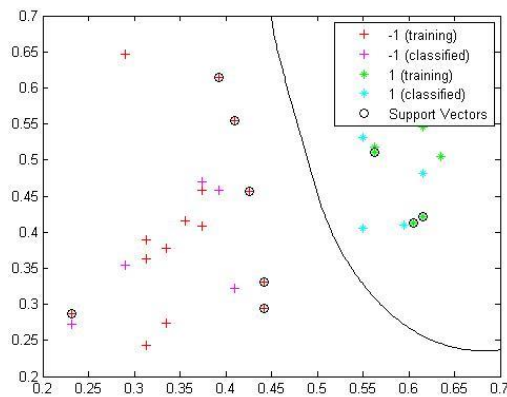


Figura 6.2. Clasificación mediante Kernel de base radial.

## 7. Conclusiones

En el presente artículo ha quedado demostrada la validez del método, en la detección temprana de un plano de rueda, sin la necesidad de desmontar la rueda para efectuar su inspección, y lo apropiado de emplear técnicas de supervisión de la condición cuando es difícil conseguir la medida directa de parámetros, así como la eficacia del análisis de la señal en el dominio temporal, a la hora de detectar este tipo de defectos.

Se ha puesto de manifiesto la validez de la Transformada de Hilbert, empleando la Curva de Lissajous, para la representación de señales mediante imágenes, pudiéndose extraer a partir de estas, mediante procesamiento digital y transformaciones morfológicas, las características necesarias para la identificación de la firma del fallo.

También se ha visto la necesidad de una adecuada selección de las mismas, para evitar redundancias e irrelevancias; en este sentido la utilización de las matrices de dispersión en la obtención de la función de evaluación de las características, en cuanto a la capacidad de separabilidad entre clases, ha demostrado ser acertada.

## 8. Bibliografía

JORDI, L.; PUIG, J.; CARDONA, S.; FLÓREZ, E., (2010), L. Jordi, J. Puig, S. Cardona. E. G. Flórez, *XVIII Congreso Nacional de Ingeniería Mecánica*.

KLOOW, L. y JENSTAV, M., (2006), «High-Speed Train Operation», en *Transrail & Swedish Rail Administration* (Banverket).

NGIGI, R.; PISLARU, C; BALL, A. y GU, F., (2012), «Modern techniques for condition monitoring of railway vehicle dynamics», *25th International Congress on Condition Monitoring and Diagnostic Engineering IOP Publishing Journal of Physics: Conference Series* 364,012016.

OTSU, N., «A threshold selection method from grey level histograms», en *IEEE Transactions on Systems, Man, and Cybernetics*. New York 9.1979, S.62–66. ISSN 1083-4419

TOURRADE, J., (1985), «Les grandes vitesses et l'optimisation des roues», en *Revue générale des chemins de fer*, vol. 103: 289-296.

VAPNIK, V.; CORTES, C.; (1995), Machine Learning, *Kluwer Academic Publishers*, Boston. 20, 273-297.

VERHEIJEN, E.; ROOVERS, M. Y VAN DEN BRENK, J, (2007), Statistical analysis of railway noise: trackside monitoring of individual trains, *Proceedings of the 9th International Workshop on Railway Noise*, IWRN, Munich, Alemania.

WARD, C.; WESTON, P.; STEWART, E.; LI, H.; GOODALL, R.; ROBERTS, C.; MEI, T.; CHARLES, G.; y DIXON, R., (2011), «Condition monitoring opportunities using vehicle-based sensors», en *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail and Rapid Transit*, vol. 225:202-218.

YENN, C.S.; LEE, J.; SHIN, H., (2010), «A review of health and operation monitoring technologies for trains», en *Smart Structures and System*, vol. 6 (9): 1079-1105.

ZHANG, J.; ZHOU, S.; y HUANG, C., A new method for the fault diagnosis of the train wheelset based on characteristic spectrum analysis, *Control Conference (CCC) 2010 29th Chinese*.