



UNIVERSIDAD DE VALLADOLID

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

MÁSTER UNIVERSITARIO EN INVESTIGACIÓN

EN TECNOLOGÍAS DE LA INFORMACIÓN Y LAS COMUNICACIONES

Análisis de vibraciones mecánicas mediante un clasificador basado en SVM para el mantenimiento predictivo de máquinas: aplicación en una cosechadora agrícola.

Autor:

D. Rubén Ruiz González

Tutores:

Dr. D. Javier Manuel Aguiar Pérez

Dr. D. Jaime Gómez Gil

Dr. D. Francisco Javier Gómez Gil

Valladolid, 12 de Septiembre de 2014

TÍTULO: **Análisis de vibraciones mecánicas mediante un clasificador basado en SVM para el mantenimiento predictivo de máquinas: aplicación en una cosechadora agrícola**

AUTOR: **D. Rubén Ruiz González**

TUTORES: **Dr. D. Javier Manuel Aguiar Pérez**
Dr. D. Jaime Gómez Gil
Dr. D. Francisco Javier Gómez Gil

DEPARTAMENTO: **TEORÍA DE LA SEÑAL Y COMUNICACIONES E INGENIERÍA TELEMÁTICA**

TRIBUNAL

PRESIDENTE: **Dr. D. Alonso Alonso Alonso**

SECRETARIO: **Dr. D. Juan Blas Prieto**

VOCAL: **Dr. D. Juan Ignacio Asensio Pérez**

FECHA: **12 de Septiembre de 2014**

CALIFICACIÓN:

Resumen

En este proyecto se presenta un método de estimación del estado de los componentes rotantes en maquinaria agro-industrial, empleando señales de vibración adquiridas de un único punto del chasis. El objetivo de este trabajo es doble: **(i)** valorar la viabilidad de detectar algunos de los estados mecánicos de los componentes rotantes en maquinaria agro-industrial empleando un único acelerómetro situado en el chasis de la máquina, y **(ii)** proponer un sistema clasificador para ese propósito y evaluar su rendimiento. Como objetivo secundario, se extraerán las características más apropiadas, dentro de aquellas contempladas en este estudio, para ser empleadas en esta aplicación concreta de análisis de señales de vibración.

PALABRAS CLAVE

Support Vector Machine (SVM), mantenimiento predictivo (PdM), maquinaria agrícola, monitorización de estado, diagnóstico de fallos, análisis de vibración, extracción y selección de características, reconocimiento de patrones.

Abstract

This work presents an automatic rotary components status estimation method for agro-industrial machinery using a vibration signal acquired from a single point in the chassis. The goal of this project is twofold: **(i)** the assessment of the feasibility of detecting several mechanical states of the rotary components in agro-industrial machinery, by just employing single accelerometer placed in the chassis of the machine, and **(ii)** the proposal of a classifying system and the evaluation of its performance. As a secondary objective, the most suitable features, amongst the contemplated ones, are extracted for this particular vibration signal analysis application.

KEYWORDS

Support Vector Machine (SVM), predictive maintenance (PdM), agricultural machinery, condition monitoring, fault diagnosis, vibration analysis, feature extraction and selection, pattern recognition.

AGRADECIMIENTOS

“Science and education, when devoid of a social conscience or environmental and human concern, are meaningless.”

Jacque Fresco

A mi familia. Por estar siempre ahí y por todo lo que hacéis para que cada día merezca la pena.

A mis amigos (Alejandro, Ana, Belén, Jorge y Loren), por vuestra presencia y apoyo a lo largo de estos años. Gracias por permitirme formar parte de vuestras vidas.

A mis tutores (Jaime, Fco. Javier y Javier) y a mis compañeros de laboratorio (Víctor, Gonzalo y Jorge). Gracias por vuestra ayuda y por soportarme durante los días de trabajo.

TABLA DE CONTENIDOS

TABLA DE CONTENIDOS	1
ÍNDICE DE FIGURAS	3
ÍNDICE DE TABLAS	5
1. INTRODUCCIÓN	7
1.1 INTRODUCCIÓN.....	7
1.2 MOTIVACIÓN.....	8
1.3 OBJETIVOS	9
1.4 METODOLOGÍA	10
1.5 ESTRUCTURA DEL TRABAJO	11
2. CONOCIMIENTOS PREVIOS	13
2.1 ANÁLISIS DE VIBRACIONES EN MAQUINARIA AGRO-INDUSTRIAL.....	13
2.2 CLASIFICACIÓN EN APRENDIZAJE SUPERVISADO DE MÁQUINAS	14
2.3 EXTRACCIÓN Y SELECCIÓN DE CARACTERÍSTICAS PARA CLASIFICACIÓN	16
2.4 CLASIFICACIÓN EMPLEANDO <i>SUPPORT VECTOR MACHINES</i>	17
3. DESCRIPCIÓN DEL PROBLEMA	23
4. TRABAJO DESARROLLADO	25
4.1 MATERIALES Y MÉTODOS	25
4.1.1 ETAPA DE ADQUISICIÓN DE DATOS.....	25
4.1.2 ETAPA DE PREPROCESADO	27
4.1.3 ETAPA DE EXTRACCIÓN Y SELECCIÓN DE CARACTERÍSTICAS	28
4.1.4 ETAPA DE CLASIFICACIÓN BASADA EN <i>SVM</i>	31
4.1.5 ETAPA DE EVALUACIÓN DE RENDIMIENTO DEL CLASIFICADOR <i>SVM</i>	32
4.2 RESULTADOS.....	32
4.2.1 SELECCIÓN DE CARACTERÍSTICAS	32
4.2.2 EVALUACIÓN DE RENDIMIENTO DEL CLASIFICADOR <i>SVM</i>	34
5. COMPARATIVA CON TRABAJOS PREVIOS	37
6. CONCLUSIONES Y LÍNEAS FUTURAS	41
6.1 CONCLUSIONES	41
6.2 LÍNEAS FUTURAS	41
BIBLIOGRAFÍA	43
ANEXO I: ARTÍCULO ENVIADO	47
ANEXO II: HISTORIAL INVESTIGADOR DEL AUTOR	73

ÍNDICE DE FIGURAS

Figura 1. Representación de un clasificador basado en *Support Vector Machine* correspondiente a (a) un patrón linealmente separable, donde el hiperplano es capaz de aislar perfectamente los círculos verdes de los cuadrados rojos, y (b) un patrón no separable linealmente, para el que no existe ningún hiperplano capaz de separar todos los círculos verdes de los cuadrados rojos..... 19

Figura 2. Representación de un clasificador basado en *Support Vector Machine* con un kernel no lineal. La función $\varphi(\cdot)$ es la transformación no lineal que mapea desde (a) el espacio de entradas hacia (b) el espacio de características. 20

Figura 3. Arquitectura de una *Support Vector Machine*. Los núcleos de producto interno, $K(\cdot, \cdot)$, denotan el producto interno m_0 -dimensional del vector de entrada con cada uno de los N_s vectores de soporte..... 22

Figura 4. Esquemático de la cosechadora. El símbolo rojo representa el punto del chasis en que fue colocado el acelerómetro. La cruz amarilla representa la ubicación del motor, la cruz azul representa la ubicación del cilindro de la trilla, y la cruz naranja representa la ubicación del picador de paja. 24

Figura 5. Diagrama de bloques resumiendo todas las etapas de procesamiento involucradas en este trabajo. 25

Figura 6. (a) Esquemático de la cosechadora, donde el símbolo rojo representa el punto del chasis en que fue colocado el acelerómetro, la cruz amarilla representa la ubicación del motor, la cruz azul representa la ubicación del cilindro de la trilla, y la cruz naranja representa la ubicación del picador de paja. (b) Ejes coordenados del acelerómetro en este estudio: el eje x es transversal a la dirección de avance de la cosechadora, el eje y apunta en el sentido opuesto a la dirección de avance de la cosechadora, y el eje z es vertical con respecto al suelo. (c) Montaje experimental para la adquisición de datos con un zoom en la localización del acelerómetro triaxial (*Kistler 8690C50*)..... 26

Figura 7. Diagrama de bloques representando las tres subetapas de preprocesado. 27

Figura 8. Número de características y *cross-validation accuracy* para cada condición de trabajo considerada –(ES) velocidad del motor, (TO) operación de la trilla, (TB) equilibrio de la trilla, (SCO) operación del picador de paja, y (SCB) equilibrio del picador de paja– usando el canal del acelerómetro correspondiente a (a) el eje transversal X, (b) el eje longitudinal Y, y (c) el eje vertical Z. 34

Figura 9. *Cross-validation accuracy* para cada *kernel* bajo las condiciones de trabajo consideradas –(ES) velocidad del motor, (TO) operación de la trilla, (TB) equilibrio de la trilla, (SCO) operación del picador de paja, y (SCB) equilibrio del picador de paja– usando el canal del acelerómetro correspondiente a (a) el eje transversal X, (b) el eje longitudinal Y, y (c) el eje vertical Z. 36

ÍNDICE DE TABLAS

Tabla 1. Resultados de la selección de características para cada uno de los tres ejes adquiridos por el acelerómetro triaxial. La fila con el número de características muestra el número óptimo requerido para lograr la mejor *cross-validation accuracy*. La fila con el mejor subconjunto de características muestra todos los subconjuntos de características concretos que resultan en la mayor *cross-validation accuracy*, ofrecidos como un listado de números cuya leyenda se corresponde con la lista suministrada en el apartado 4.1.3. Resaltado en negrita se encuentra aquél subconjunto que ha sido empleado en la posterior etapa de evaluación del rendimiento del clasificador (apartado 4.2.2). Cada columna se corresponde con el problema de clasificación asociado a cada componente rotante considerado. 33

Tabla 2. Resultados de rendimiento para cada uno de los tres ejes del acelerómetro triaxial, comparando los diferentes *kernels* SVM utilizados. Los parámetros optimizados (C , γ , c_0) así como la mejor *cross-validation accuracy* (CVA) son mostrados. El mejor resultado de cada problema de clasificación se resalta en negrita. 35

INTRODUCCIÓN

1.1 Introducción

La maquinaria agro-industrial es un equipamiento costoso que requiere de un mantenimiento cuidadoso y de alto nivel para evitar costes mayores en subsiguientes tareas de reparación [1]. La necesidad y bondad de un mantenimiento planificado de la maquinaria es un tema que ha sido bien argumentado tanto en la industria como en la literatura de investigación académica asociada [2]. Una detección temprana del mal funcionamiento de un componente mecánico permite su reemplazo inmediato, evitándose así reparaciones futuras que sean considerablemente más costosas.

Hoy en día, muchas técnicas de mantenimiento predictivo se emplean con el propósito de reducir riesgos y evitar fallos posteriores [1-3]. Las principales técnicas, según Scheffer *et al.* [4], son la monitorización de vibraciones, la emisión acústica, el análisis de aceites, el análisis de partículas, la monitorización de la corrosión, la termografía, y la monitorización del rendimiento.

El análisis de vibraciones es un método de monitorización del estado no intrusivo ampliamente utilizado en las inspecciones de maquinaria, principalmente para equipamiento rotante incluyendo motores, turbinas, y compresores, entre otros [4-6]. En los casos de maquinaria en los que no se aplica un aislamiento mecánico de las vibraciones, las señales de vibración se propagan a través de toda la estructura de la máquina con una atenuación moderada. Este hecho hace posible monitorizar algunos componentes rotantes situando un acelerómetro en cualquier otra posición de la estructura de la máquina [7]. No obstante, esta capacidad de propagación tiene también la desventaja de superponer otras señales de vibración, procedentes de otros componentes mecánicos de la estructura de la máquina, junto con la señal de interés. Esta superposición hace mucho más difícil la extracción de información relevante de la señal de vibración adquirida [8].

Las señales de vibración de los componentes rotantes son comúnmente analizadas en el dominio frecuencial, debido al hecho de que picos de una amplitud significativa aparecen en el espectro de la señal en ciertas frecuencias que están relacionadas con la frecuencia de rotación del componente bajo análisis [4]. Algunos autores han llevado a cabo este análisis empleando la transformada rápida de Fourier [9], la transformada de Fourier de tiempo corto [10], la transformada wavelet [11-13], la transformada S [14], o la transformada de Hilbert-Huang [13, 15-17], entre otras. Debido a la relación existente entre la frecuencia de rotación de los componentes de la máquina y los picos de mayor amplitud en el espectro de la señal, aquellas personas con una gran experiencia son capaces de estimar el estado de dichos componentes buscando patrones reconocibles en el espectro. No obstante, para poder hacerlo se necesita del análisis del espectro de la señal de vibración por parte de expertos, los cuáles además deben tener un conocimiento detallado sobre el funcionamiento de la máquina así como información completa acerca de la velocidad de rotación del componente analizado. Algunos sistemas automatizados ya existentes han propuesto estimar el estado de ciertos componentes de maquinaria empleando análisis en frecuencia y sin la necesidad de una persona experta [13, 18]. Estos sistemas incorporan el conocimiento sobre el componente concreto para poder extraer características a partir del espectro de la señal y estimar el estado en función de dichas características.

Las máquinas de vectores de soporte (*Support Vector Machines*, SVM) [19] son modelos de aprendizaje supervisado, empleados asiduamente en la disciplina del reconocimiento de patrones con propósitos de clasificación. Debido a sus buenas capacidades de aprendizaje y generalización, son una herramienta muy apropiada para la implementación de métodos de estimación, métodos de estimación que son ampliamente requeridos en los sistemas de diagnóstico automático. De acuerdo con la revisión del estado del arte, muchas aplicaciones basadas en SVMs se han llevado a cabo de manera satisfactoria [20], por ejemplo en clasificación [21] y regresión no lineal [22]. Centrándose más específicamente en el campo de la monitorización de vibraciones para el diagnóstico de fallos mecánicos, muchas mejoras han aparecido en los últimos años [23, 24]. Widodo y Yang [25] ofrecieron una revisión muy completa del estado del arte donde recopilan los principales avances que se han producido en los últimos años dentro del campo del análisis de vibraciones basado en SVMs para el mantenimiento predictivo.

1.2 Motivación

En la actualidad, los sistemas de mantenimiento predictivo de maquinaria mediante análisis de vibraciones necesitan desmontar del resto de la

maquinaria los componentes mecánicos que van a ser analizados. Esto conlleva que las inspecciones sean costosas y prolongadas en el tiempo, a lo que encima hay que añadir el transporte de éstas hasta lugares específicos donde dichas inspecciones se pueden realizar.

Es por todas estas complicaciones antes mencionadas por las que las revisiones periódicas de maquinaria agro-industrial son muchas veces postergadas. Esa ausencia de frecuentes revisiones da lugar, en muchas ocasiones, a fallos graves y reparaciones muy costosas que podrían haberse evitado con una planificación adecuada del proceso de mantenimiento.

El motivo por el que surge el presente Trabajo Fin de Máster es, precisamente, el de dar respuesta a la imperante necesidad de simplificar las revisiones, acercando y facilitando al usuario final su empleo. Con la implantación ubicua del sistema propuesto en el presente trabajo se trata de alcanzar una gestión mucho más eficiente de los costosos recursos implicados en la maquinaria agro-industrial.

Pese a que un gran número de trabajos de investigación han sido realizados con anterioridad dentro del campo del mantenimiento predictivo de maquinaria [18, 25], hasta donde alcanza nuestro conocimiento, ninguna investigación llevada a cabo hasta la fecha ha abordado la predicción automática del estado de múltiples componentes rotantes de una máquina agro-industrial entera empleando tan sólo una única señal de vibración adquirida de un solo punto del chasis de la máquina.

1.3 Objetivos

El principal objetivo de este trabajo es realizar una prueba de concepto, sin pretender hacer un estudio más extenso sobre su generalidad, para valorar la capacidad de predecir el estado de múltiples componentes mecánicos rotantes en maquinaria agro-industrial, empleando como entrada al sistema tan sólo la señal de vibración adquirida de un único punto del chasis de la máquina.

Para lograr alcanzar este objetivo principal se definen varios objetivos intermedios, que mediante su realización, ayuden a conseguirlo. Éstos se encuentran detallados a continuación:

- Diseñar un sistema que sea capaz de diagnosticar el estado de múltiples componentes mecánicos de una máquina agro-industrial a partir de los datos de vibración tomados en un único punto del chasis de la máquina.
- Evaluar el sistema en una cosechadora agrícola, considerando los cinco siguientes estados en alguno de los componentes mecánicos rotantes: (1) el estado de velocidad del motor (*máximo/ralentí*), (2) el estado de funcionamiento de la trilla (*on/off*), (3) el estado de equilibrio de la trilla (*equilibrado/desequilibrado*), (4) el estado de funcionamiento

del picador (*on/off*), and (5) el estado de equilibrio del picador (*equilibrado/desequilibrado*).

- Evaluar la adecuación de un clasificador SVM a la hora de diagnosticar el estado de múltiples componentes mecánicos de una máquina agro-industrial a partir de los datos de vibración adquiridos en un único punto del chasis de la máquina.

De manera adicional y complementaria, se pretende evaluar la capacidad de diagnosticar esos estados empleando algunas características diferentes a las empleadas tradicionalmente en la literatura del campo de análisis de vibraciones.

1.4 Metodología

La metodología utilizada a la hora de afrontar la resolución de este Trabajo Fin de Máster (TFM) se ha basado en seis fases.

La primera fase ha consistido en la búsqueda de información relativa al análisis de vibraciones. Esta documentación es necesaria para poder comprender sus fundamentos y poder diseñar el sistema que cumpla con los requisitos marcados en el objetivo de este Trabajo Fin de Máster.

La segunda de las fases ha consistido en una revisión del estado del arte sobre sistemas de análisis de vibraciones con el fin de analizar los sistemas existentes. Esta fase es esencial para poder tomar ideas de trabajos precedentes, garantizar la originalidad de la propuesta y establecer una comparativa frente al estado del arte.

Con dicho conocimiento previo en la mano, en la tercera fase se ha pasado a proponer la solución del sistema a implementar. En esta fase se ha diseñado un sistema que sea capaz de cumplir con los objetivos y requisitos establecidos. Además se han identificado las tecnologías a utilizar así como se ha determinado cuáles van a ser las posteriores fases para alcanzar el objetivo marcado.

En la cuarta fase, se ha procedido a realizar los tests experimentales junto con un análisis exploratorio inicial. Este análisis exploratorio, nuevamente, ha permitido refinar el diseño planteado en la fase anterior.

Con los conocimientos previos junto con las ideas que han aflorado en los test experimentales iniciales, se ha pasado a definir e implementar el sistema completo, en lo que ha constituido la quinta fase.

Por último, en la sexta fase se ha evaluado el sistema propuesto, comprobando su funcionamiento en el entorno experimental y comparando, en la medida de lo posible, dichos datos con los trabajos similares encontrados

previamente en la literatura. De dicha comparativa con la literatura científica relacionada, se detectan y analizan las mejoras que supone el sistema implementado en este trabajo, tratando de dejar patente la contribución de este trabajo así como su originalidad.

1.5 Estructura del trabajo

Esta memoria de Trabajo Fin de Máster (TFM) se encuentra dividida en 6 capítulos.

En el Capítulo 1, en el cual se enmarca este apartado, se realiza una introducción al tema desarrollado, con un somero estudio sobre los sistemas de análisis de vibraciones para el mantenimiento predictivo existentes en la literatura. Además se ofrece una descripción de los objetivos del trabajo y la metodología utilizada para su realización.

En el Capítulo 2 se explican algunos de los conocimientos previos teóricos necesarios tanto para realizar como para comprender mejor la problemática descrita en este trabajo. En esta sección se recopilan fundamentos básicos sobre análisis de vibraciones para el mantenimiento predictivo y clasificación basada en SVM.

En el Capítulo 3 se pasa a describir el problema abordado, y posteriormente resuelto, en este trabajo. De este modo se introduce al lector al trabajo realizado durante este Trabajo Fin de Máster.

En el Capítulo 4 se pasa a describir el trabajo desarrollado en este TFM. En él se detallan los materiales y métodos, empleados en la realización de este trabajo, incluyendo la arquitectura del sistema propuesto y los mecanismos de evaluación del mismo. Adicionalmente se detallan los principales resultados derivados del trabajo.

A continuación, en el Capítulo 5 se discuten los resultados obtenidos del trabajo desarrollado, analizando las alternativas del sistema implementado, y se ofrece una somera comparativa frente a otros trabajos similares existentes en la literatura.

Para finalizar, en el Capítulo 6 se detallan las conclusiones obtenidas de la realización del trabajo y algunas líneas futuras que surgen a partir de éste.

Adicionalmente se incluye la bibliografía consultada y utilizada para la redacción de este trabajo.

A modo de apéndice, se incluye un anexo donde se adjunta el artículo científico que ha sido elaborado durante el desarrollo de este Trabajo Fin de

Máster, de manera simultánea a esta memoria. A fecha de entregar esta memoria del TFM, el artículo había sido enviado para su publicación a la revista “*Sensors*” sin respuesta sobre su aceptación o rechazo.

CONOCIMIENTOS PREVIOS

2.1 Análisis de vibraciones en maquinaria agro-industrial

Las vibraciones, en palabras llanas, se puede definir como el movimiento de vaivén de un determinado punto con respecto a su posición de equilibrio. Los dispositivos más populares para captar señales de vibración mecánica en aplicaciones de maquinaria rotante son los acelerómetros. Un acelerómetro es un sensor que mide la aceleración física experimentada por un objeto. Los acelerómetros pueden capturar señales en un rango frecuencial que va típicamente desde 1Hz hasta los 10kHz [4].

Los defectos más comunes que causan altos niveles de vibración en el caso de maquinaria, de acuerdo con Scheffer *et al.* [4], son: los desequilibrios de partes rotantes, las alineaciones incorrectas de acoplamientos y rodamientos, los ejes doblados, las marchas y rodamientos desgastados o dañados, las cadenas y correas de transmisión deterioradas, las variaciones de torque, los campos electromagnéticos, las fuerzas aerodinámicas, las fuerzas hidráulicas, las holguras, los roces, y las resonancias. Cuando los componentes rotantes operan a altas velocidades o bajo condiciones de trabajo duras durante un tiempo prolongado, algunos de estos defectos comienzan a aparecer.

Las vibraciones pueden revelar la presencia de defectos en los componentes mecánicos. Habitualmente, las vibraciones en componentes rotantes aparecen en frecuencias específicas, que son características de cada componente concreto y también dependen de la velocidad de giro y otras propiedades del componente en cuestión [13, 18]. Tradicionalmente, dependiendo de la amplitud de las vibraciones en dichas frecuencias específicas, la severidad de los defectos puede ser valorada. Así, una gran cantidad de información acerca de la condición de un componente, por ejemplo un posible deterioro, puede ser

obtenida a través de un análisis de las características de vibración de componentes aislados [4].

Además, las señales de vibración de un componente específico se pueden adquirir en un punto distante de la estructura de la máquina, aunque ligeramente atenuadas, debido tanto a la capacidad de propagación que exhibe la estructura de la máquina como al aislamiento imperfecto de las principales fuentes de vibraciones. Esta capacidad de propagación hace considerablemente más difícil el procesamiento para extraer información útil debido a la mezcla de información de varios componentes de la maquinaria, pero a su vez simplifica la etapa de adquisición de datos, limitando la instalación de sensores únicamente a un solo punto de la máquina.

2.2 Clasificación en aprendizaje supervisado de máquinas

El aprendizaje en máquinas (*machine learning*), como subcampo de la inteligencia artificial dentro de la informática, trata con sistemas que pueden aprender a partir de los datos, modificando su comportamiento dependiendo de sus datos de entrada. Para poder aprender a partir de los datos, el sistema típicamente debe tener la capacidad de deducir la función subyacente a los datos de entrada. El aprendizaje en máquinas se puede dividir en aprendizaje no supervisado y aprendizaje supervisado, dependiendo de cuanta información es suministrada en el proceso de aprendizaje. El aprendizaje no supervisado aborda el proceso de inferencia de la función que subyace tras los datos de entrada usando un conjunto de entrenamiento no etiquetado, es decir sin ninguna información sobre la salida deseada para dicha entrada, e intenta deducir relaciones buscando similitudes en el conjunto de datos de entrenamiento. Por su parte, el aprendizaje supervisado asume que está disponible un conjunto de entrenamiento perfectamente etiquetado, para el cual la salida deseada es conocida con certeza absoluta.

La clasificación, como una rama del aprendizaje supervisado que es, se define como el proceso de identificar la clase a la que pertenece una nueva observación, previamente desconocida, basándose en el conocimiento previo dado por un conjunto de entrenamiento que contiene muestras de ejemplo cuya categoría de pertenencia es conocida por completo. Cualquier algoritmo que realiza tareas de clasificación, es decir el mapeo de los datos de entrada a una clase asignada, se conoce como clasificador.

Los clasificadores deben ser entrenados, basándose en un conocimiento previo, para que funcionen correctamente. El proceso de entrenamiento utiliza una muestra de N observaciones, para las cuales su clase correspondiente es conocida. Esta muestra de N observaciones es típicamente dividida en dos

subconjuntos: el conjunto de entrenamiento y el conjunto de test. En primer término, el conjunto de entrenamiento es empleado en el proceso de calcular un clasificador que se adapte de manera precisa a esos datos. Después, el conjunto de test se utiliza para valorar la capacidad de generalización del clasificador que ha sido calculado con anterioridad.

Con la finalidad de evaluar el rendimiento de un clasificador, la tasa de clasificación errónea y la tasa de acierto, en el conjunto de test, se suelen emplear como medida de su calidad. La tasa de clasificación errónea (*Misclassification Rate, MR*) se define como la proporción de observaciones que son asignadas de manera errónea a una clase incorrecta, y se calcula según la siguiente fórmula:

$$MR = \frac{\text{Número de Clasificaciones Incorrectas}}{\text{Número Total de Clasificaciones}}$$

Alternativamente, la tasa de acierto o tasa de éxito (*Success Rate, SR*) se define como la proporción de observaciones que son correctamente asignadas a la clase correspondiente, y se calcula como el siguiente cociente:

$$SR = \frac{\text{Número de Clasificaciones Correctas}}{\text{Número Total de Clasificaciones}} = 1 - MR$$

Una manera mejorada y más precisa de evaluar el rendimiento de un clasificador, especialmente cuando los conjuntos de entrenamiento y test tienen un tamaño muy reducido, es empleando técnicas de validación cruzada (*cross-validation*). En la *k-fold cross-validation*, la muestra original de N observaciones es particionada aleatoriamente en k subconjuntos de igual tamaño. A partir de esos k subconjuntos, un único subconjunto se emplea como conjunto de test y los $k-1$ subconjuntos restantes son usados como conjunto de entrenamiento. El método de la *k-fold cross-validation* repite este proceso de entrenamiento y test k veces, usando como conjunto de test exactamente una sola vez cada uno de dichos k subconjuntos. La precisión de validación cruzada (*cross-validation accuracy*) se calcula como el promedio de la tasa de acierto (*success rate*) obtenida para cada uno de los k diferentes conjuntos de entrenamiento. Cuando $k=N$, el método de *k-fold cross-validation* se conoce también como *leave-one-out cross-validation*.

Multitud de clasificadores diferentes han sido propuestos en la literatura hasta la fecha [26, 27]. Alguno de los principales y más empleados

clasificadores incluye el clasificador de vecino más cercano (*k-nearest neighbor classifier*), los clasificadores Bayesianos (*Bayes classifier*), la regresión logística (*logistic regression*), el discriminante lineal de Fisher (*Fisher's linear discriminant*), los árboles de decisión (*decision tree*), las redes neuronales artificiales (*Artificial Neural Networks, ANN*), y las máquinas de vectores de soporte (*Support Vector Machines, SVM*). Dado que en este trabajo se va a emplear un clasificador basado en SVM, los principios básicos de las SVM se recogen con mayor detalle en el apartado 2.4.

2.3 Extracción y selección de características para clasificación

Los sistemas de *machine learning*, incluyendo los clasificadores, típicamente necesitan procesar ingentes cantidades de información. Una manera de evitar que el clasificador procese muchos datos, y así mejore su rendimiento, es aplicando técnicas de reducción de la dimensionalidad sobre los datos de entrada. La reducción de dimensionalidad, dentro del campo del aprendizaje estadístico de máquinas, se define como el proceso de reducir el número de variables de un conjunto de datos mientras se conservan la mayoría de sus grados de libertad. De este modo se logra simplificar el problema de clasificación posterior sin tener pérdida de información esencial. Los dos métodos principales de lograr la reducción de la dimensionalidad para clasificación son los métodos de extracción y selección de características.

La extracción de características (*feature extraction*) [26] es una técnica que consiste en reducir las dimensiones de un vector de entrada d -dimensional, transformándolo en un nuevo vector de salida m -dimensional, donde $m < d$. El vector m -dimensional resultante, llamado vector de características, debe mantener la mayor parte de la información útil, con respecto al vector original, para la etapa de clasificación posterior. Esta propiedad que debe cumplir el vector de características es típicamente referida como preservación de los grados de libertad. En función del tipo de datos, las características puede ser categóricas, ordinales, con valor entero, con valor real, etc. Dentro de la amplia variedad de algoritmos de extracción de características existentes en la literatura científica [28-31], una posible taxonomía puede llevarse a cabo en función de la relación de las características con campos matemáticos específicos. Las categorías de características más populares dentro de esta clasificación son: características no lineales, características estadísticas y características basadas en dominio transformado. Algunas de las principales características no lineales son la dimensión de correlación (*Correlation Dimension*) [32], la complejidad de Kolmogorov (*Kolmogorov Complexity*) [33], la complejidad de Lempel-Ziv (*Lempel-Ziv Complexity*) [28, 34], la entropía

aproximada (*Approximate Entropy*) [35], y la entropía muestral (*Sample Entropy*) [36]. Métodos estadísticos de extracción de características basadas en el dominio temporal incluyen el valor medio, la desviación estándar, la asimetría estadística (*skewness*), la curtosis (*kurtosis*), la potencia media, y la entropía de Shannon (*Shannon Entropy*) [37]. Algunas de las técnicas más reseñables de extracción de características en el dominio frecuencial son la entropía espectral (*Spectral Entropy*) [29], la frecuencia mediana (*Median Frequency*) [30, 38], el ancho de banda que contiene el 90% de la energía de la señal, y la energía relativa de paquetes wavelet (*Relative Wavelet Packet Energy*) [31].

La selección de características (*feature selection*) [26], por su parte, consiste en escoger, entre un conjunto original de m características, aquel subconjunto de tamaño n que mejor representa al conjunto de partida, en el sentido de conducir al menor error de clasificación. El proceso de selección de características puede ser llevado a cabo, entre otros métodos, por medio de los algoritmos de búsqueda exhaustiva (*Exhaustive Search*) o bien búsqueda secuencial (*Sequential Forward/Backward Floating Search*) [26]. Por un lado, la búsqueda exhaustiva explora todos los posibles subconjuntos, es decir 2^m si n es un parámetro libre, o $\binom{m}{n}$ si n es una constante prefijada. Por lo tanto, este método garantiza la selección del mejor subconjunto, pero por contra es muy costoso computacionalmente. Por otro lado, la búsqueda secuencial restringe la búsqueda a un subárbol más pequeño, permitiendo simplemente añadir y eliminar algunas características del conjunto seleccionado en cada paso. En consecuencia, este método ofrece una carga computacional mucho más asumible, pero sin embargo no garantiza la selección del subconjunto de características óptimo. Aún así, se ha comprobado que los resultados subóptimos ofrecidos por la búsqueda secuencial (*Sequential Forward/Backward Floating Search*) están muy cercanos a la optimalidad.

La mejora de rendimiento, ofrecida por las técnicas de extracción y selección de características, procede de (i) la reducción de dimensión, que reduce el riesgo de sobreajustar en tanto en cuanto mitiga el problema de la maldición de la dimensionalidad (*curse of dimensionality*) [26, 39], y (ii) la simplificación del clasificador resultante, lo que conlleva a usar menos memoria y recursos computacionales [26].

2.4 Clasificación empleando *Support Vector Machines*

Las máquinas de vectores de soporte (*Support Vector Machines*, SVM) es una técnica estadística de aprendizaje supervisado, empleada tanto con propósitos de clasificación como de regresión. Fue originalmente propuesta en 1995 por Vapnik y Cortes [19, 40]. Aunque sus principios y derivación difieren

de los de las redes neuronales artificiales (*Artificial Neural Networks*, ANN), algunos autores a veces consideran las SVM como un tipo especial de ANN [41]. Sin embargo, muchos autores se niegan a considerarlas como tal debido a diferencias esenciales entre las técnicas de SVM y ANN [42]. Mientras que los mecanismos de las SVMs están principalmente basados en un riguroso enfoque estadístico-geométrico, las ANNs intentan emular el comportamiento del sistema neuronal del cerebro humano.

La encarnación original de las SVM, en cuanto a clasificación, atajaba tanto el problema de clasificación binario, que sólo considera dos posibles clases de clasificación, como el problema de clasificación multiclase, que considera más de dos clases de clasificación.

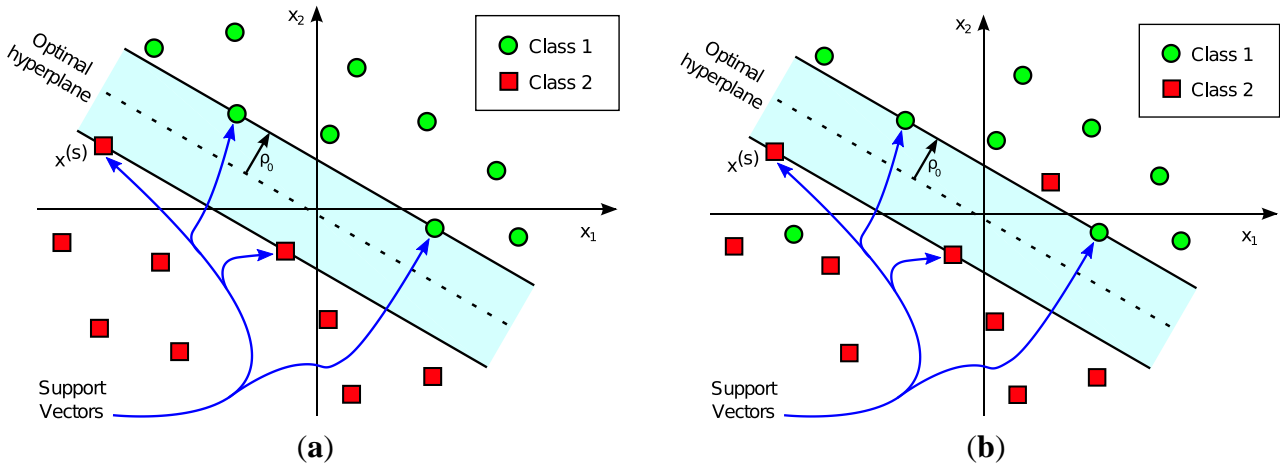
En el problema binario de clasificación SVM lineal el cálculo de la frontera de decisión, o hiperplano óptimo, que separa ambas clases se realiza empleando el conjunto de entrenamiento. La optimalidad puede ser entendida, dependiendo de si se puede y desea lograr una clasificación perfecta en el conjunto de entrenamiento, de dos formas:

- Si una perfecta separabilidad de ambas clases puede ser lograda en el conjunto de entrenamiento, la optimalidad de margen estricto (*Hard Margin*) se puede emplear. En este caso, el hiperplano que actúa como frontera de decisión se escoge de manera que maximice la distancia desde el hiperplano hasta el punto más próximo del conjunto de entrenamiento.
- Si una clasificación perfecta no es posible o deseada, la optimalidad de margen débil (*Soft Margin*) es empleada. En este caso, la selección del hiperplano es un compromiso ajustable entre minimizar la tasa de clasificación errónea y maximizar la distancia desde el hiperplano hasta el punto más próximo del conjunto de entrenamiento.

El hiperplano que actúa como frontera de decisión en la clasificación basada en SVM es calculado empleando el conjunto de entrenamiento. Esta frontera de decisión queda completamente determinada por lo que se conocen como vectores de soporte (*Support Vectors*), un subconjunto de los vectores de entrada para el entrenamiento que por sí mismos solos determinan completamente la frontera de decisión. Después de que este hiperplano ha sido determinado, el clasificador SVM está listo para ser empleado con un conjunto de datos nuevo, diferente al usado en la etapa de entrenamiento. La clase asignada, etiquetada como +1 o -1, se decide en función de en qué lado de la frontera de decisión cae el vector de entrada. La Figura 1 representa un ejemplo gráfico de clasificación lineal basada en SVM, tanto en el caso de clases linealmente separables como de clases no separables linealmente.

Por su parte, la clasificación multiclase basada en SVM habitualmente aborda el cálculo de la frontera de decisión reduciendo el problema a un conjunto de subproblemas de clasificación binaria. Los dos principales enfoques son los métodos de clasificación por parejas (*pairwise*) y uno frente a todos (*one-versus-all*) [43]. Además, reformulaciones compactas del problema binario para convertirlo en un problema multiclase también se han propuesto [43].

Figura 1. Representación de un clasificador basado en *Support Vector Machine* correspondiente a (a) un patrón linealmente separable, donde el hiperplano es capaz de aislar perfectamente los círculos verdes de los cuadrados rojos, y (b) un patrón no separable linealmente, para el que no existe ningún hiperplano capaz de separar todos los círculos verdes de los cuadrados rojos.



El problema binario de clasificación SVM lineal más general, siendo matemáticamente rigurosos, se plantea como sigue:

“Dado un conjunto de entrenamiento, $\{\mathbf{x}_i, d_i\}_{i=1}^N$, el objetivo es calcular el vector de pesos \mathbf{w} , el sesgo b , y las variables holgadas ξ óptimas, tales que satisfacen las siguientes restricciones:

$$d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \forall i = 1, 2, \dots, N$$

$$\xi_i \geq 0, \forall i = 1, 2, \dots, N$$

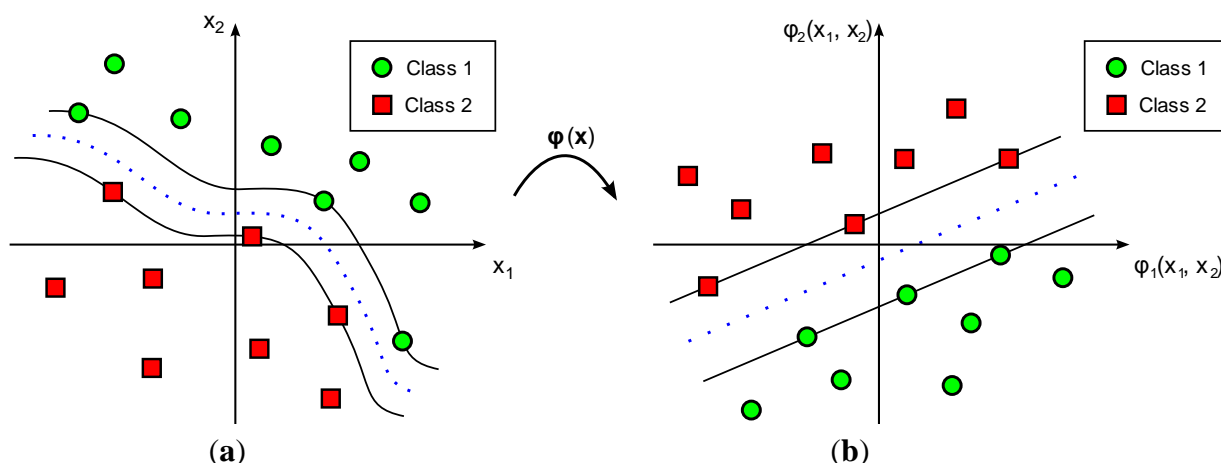
y tal que la siguiente función de coste es minimizada:

$$\Phi(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N \xi_i$$

donde $\mathbf{x}_i \in \mathbb{R}^{m_0}$ denota cada uno de los N vectores de entrada, $d_i \in \{-1, 1\}$ denota la clase correspondiente al i -ésimo vector de entrada, $\xi = \{\xi_i\}_{i=1}^N$ son las distancias o márgenes de tolerancia de clasificación errónea, y la constante C es un parámetro especificado por el usuario que determina el compromiso entre clasificación errónea y máximo margen entre clases.”

En la práctica, la mayoría de problemas de clasificación no pueden ser resueltos empleando un simple hiperplano como frontera de decisión. En tales casos una frontera de decisión más compleja y elaborada es requerida. Las SVMs logran este objetivo incrementando la dimensionalidad del espacio de entrada, de dimensión m_0 , aplicando una transformación no lineal, denotada por $\varphi(\cdot)$, hacia un espacio de características de dimensión $m_f > m_0$ (Figura 2). Esta transformación, $\varphi(\cdot)$, se lleva a cabo con la esperanza de ser capaz de reducir la probabilidad de clasificación errónea en el espacio transformado. Las funciones o transformaciones más típicas, al igual que en el caso de las ANNs, son las funciones de base radial, polinomios de orden superior y sigmoides. La Figura 2 representa un ejemplo gráfico de clasificación SVM no lineal.

Figura 2. Representación de un clasificador basado en *Support Vector Machine* con un kernel no lineal. La función $\varphi(\cdot)$ es la transformación no lineal que mapea desde (a) el espacio de entradas hacia (b) el espacio de características.



La frontera en el problema de clasificación no lineal es todavía un hiperplano, pero no en el espacio de entradas original sino en el espacio transformado de características. Esta frontera se puede expresar como los puntos $\varphi(x)$ que satisfacen que:

$$\mathbf{w}^T \varphi(x) + b = 0 \quad (1)$$

donde $x \in \mathbb{R}^{m_0}$ y $\varphi(x) \in \mathbb{R}^{m_f}$.

Ha sido demostrado, tras aplicar el método de los multiplicadores de Lagrange, que el vector de pesos óptimo se puede expresar como [41]:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \varphi(x_i) \quad (2)$$

donde α_i denota los coeficientes multiplicadores de Lagrange.

De esta manera, la frontera de decisión óptima se puede reescribir como:

$$\sum_{i=1}^N \alpha_i d_i \boldsymbol{\varphi}(\mathbf{x}_i)^T \boldsymbol{\varphi}(\mathbf{x}) + b = 0 \quad (3)$$

Renombrando $u_i = \alpha_i d_i$ y $K(\mathbf{x}_i, \mathbf{x}) = \boldsymbol{\varphi}(\mathbf{x}_i)^T \boldsymbol{\varphi}(\mathbf{x}) = \boldsymbol{\varphi}(\mathbf{x})^T \boldsymbol{\varphi}(\mathbf{x}_i) = K(\mathbf{x}, \mathbf{x}_i)$, la función que actúa de frontera de decisión, y , se puede escribir como:


$$y = \sum_{i=1}^N u_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (4)$$

En el caso de clasificadores lineales, $K(\mathbf{x}, \mathbf{x}_i)$ es el producto interno euclídeo convencional de la entrada, \mathbf{x} , con el vector de soporte \mathbf{x}_i . En el caso de clasificadores no lineales, $K(\mathbf{x}, \mathbf{x}_i)$ es el producto interno euclídeo convencional de la transformación no lineal de la entrada, $\boldsymbol{\varphi}(\mathbf{x})$, con la transformación no lineal del vector de soporte, $\boldsymbol{\varphi}(\mathbf{x}_i)$.

La función de decisión representada en la Ecuación (4) resulta en la arquitectura representada en la Figura 3, una vez que los pesos adecuados, u_i , y los vectores de soporte, \mathbf{x}_i , han sido calculados en la etapa de entrenamiento. Dado que sólo los vectores de soporte contribuyen con coeficientes α_i no nulos [41], sólo dichos vectores de soporte deben ser tenidos en cuenta.

Por tanto, la clasificación es llevada a cabo mirando el signo del valor de salida, y , en la Ecuación (4). Si el $\text{signo}(y) = +1$, entonces la entrada correspondiente se etiqueta como perteneciente a la clase +1. En caso contrario ésta es etiquetada como clase -1.

Figura 3. Arquitectura de una *Support Vector Machine*. Los núcleos de producto interno, $K(\cdot, \cdot)$, denotan el producto interno m_0 -dimensional del vector de entrada con cada uno de los N_s vectores de soporte.



Los núcleos (*kernels*) no lineales más conocidos y ampliamente empleados son las funciones de base radial (*Radial Basis Functions, RBF*), las sigmoides (*sigmoids*), y los polinomios de orden superior (*higher-order polynomials*). El núcleo *RBF* se puede expresar como $K(x, y) = \exp(-\gamma \|x - y\|^2)$, donde γ es un parámetro especificado por el usuario, el núcleo *sigmoidal* se puede expresar como $K(x, y) = \tanh(\gamma x^T y + c_0)$, donde $\gamma > 0$ y $c_0 < 0$ son parámetros especificados por el usuario, y el núcleo polinómico de orden d se puede expresar como $K(x, y) = (\gamma x^T y + c_0)^d$, donde γ y c_0 son parámetros especificados por el usuario y d denota el grado del polinomio. Además de estos núcleos, otros existen también.

El proceso de entrenamiento que subyace tras las SVM aborda el problema de minimizar un funcional cuadrático sujeto a restricciones lineales. Este problema, conocido como *Quadratic Programming*, tiene una solución cerrada. Aunque dicha solución puede calcularse analíticamente haciendo uso del método de los multiplicadores de Lagrange, otros métodos computacionales son empleados típicamente, especialmente cuando la dimensionalidad del problema es grande. Algunos de dichos métodos incluyen, entre otros, métodos de punto interior (*Interior Point*) [44], el algoritmo SMO (*Sequential Minimal Optimization*) [45, 46], métodos incrementales (*Incremental*) [47], y el algoritmo KA (*Kernel-Adatron*) [48]. Más información sobre el proceso de entrenamiento de las SVM se encuentra recopilada en el libro escrito por Campbell y Ying [49].

Aquél lector ávido por descubrir el planteamiento matemático riguroso y la solución subyacente al problema de las *Support Vector Machines* es animado encarecidamente a leer la introducción comprensible ofrecida por Haykin [41] o el libro, más árido pero más completo, de Steinwart y Christmann [50].

DESCRIPCIÓN DEL PROBLEMA

El trabajo desarrollado en este documento aborda la extensión y mejora de los actuales sistemas de mantenimiento predictivo de maquinaria mediante análisis de vibraciones. Los estudios previos realizados en este campo necesitan desmontar los componentes mecánicos que van a ser analizados antes de diagnosticar su estado. Esto conlleva a costosas y prolongadas inspecciones, a las que hay que añadir el transporte a lugares específicos donde dichas inspecciones se pueden realizar.

El motivo por el que surge el presente Trabajo Fin de Máster es precisamente el de dar respuesta a la necesidad de simplificar las revisiones, acercando y facilitando al usuario final su empleo. Con la implantación ubicua del sistema propuesto en el presente trabajo se trata de alcanzar una gestión mucho más eficiente de los costosos recursos implicados en la maquinaria agro-industrial.


Pese a que numerosos trabajos de investigación han sido realizados con anterioridad para el mantenimiento predictivo de maquinaria [18, 25], hasta donde alcanza nuestro conocimiento, ninguna investigación llevada a cabo hasta la fecha ha abordado la predicción automática del estado de múltiples componentes rotantes de una máquina agro-industrial entera empleando sólo una única señal de vibración adquirida de un solo punto del chasis de la máquina.

En este sentido, el principal objetivo de este trabajo es realizar una prueba de concepto para valorar la capacidad de predecir el estado de múltiples componentes mecánicos rotantes en maquinaria agro-industrial, empleando

como entrada al sistema tan sólo la señal de vibración adquirida de un único punto del chasis de la máquina. Adicionalmente, se tratará de cuantificar la precisión alcanzada para determinar la viabilidad de alcanzar dicho objetivo.

De una manera muy resumida, el presente estudio trata de de estimar el estado de tres componentes mecánicos diferentes (motor, trilla y picador de paja) a partir de la señal de vibración adquirida en un solo punto del chasis de la maquina (Figura 4).

Figura 4. Esquemático de la cosechadora. El símbolo rojo representa el punto del chasis en que fue colocado el acelerómetro. La cruz amarilla representa la ubicación del motor, la cruz azul representa la ubicación del cilindro de la trilla, y la cruz naranja representa la ubicación del picador de paja.



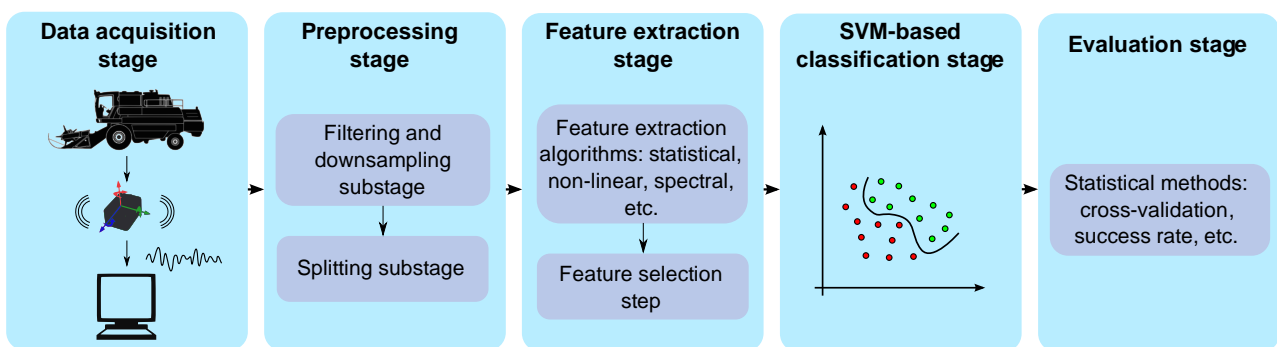
Como resulta evidente a partir de la Figura 4, el acelerómetro que captura la señal de vibración se encuentra relativamente lejos de los elementos a analizar. Los estados analizados sobre cada uno de los tres componentes seleccionados en este estudio fueron los cinco siguientes: (1) el estado de velocidad del motor (*máximo/ralentí*), (2) el estado de funcionamiento de la trilla (*on/off*), (3) el estado de equilibrio de la trilla (*equilibrado/desequilibrado*), (4) el estado de funcionamiento del picador (*on/off*), and (5) el estado de equilibrio del picador (*equilibrado/desequilibrado*).

TRABAJO DESARROLLADO

4.1 Materiales y métodos

Los métodos llevados a cabo en este trabajo se dividen en las siguientes etapas: (i) etapa de adquisición de datos (Sección 4.1.1), (ii) etapa de preprocesado (Sección 4.1.2), (iii) etapa de extracción y selección de características (Sección 4.1.3), (iv) etapa de clasificación basada en SVM (Sección 4.1.4), y (v) etapa de evaluación (Sección 4.1.5). Con el fin de representar una descripción de alto nivel de los métodos, la Figura 5 sintetiza las principales etapas y subetapas, que son explicadas con mayor nivel de detalle a lo largo de esta sección.

Figura 5. Diagrama de bloques resumiendo todas las etapas de procesado involucradas en este trabajo.




4.1.1 Etapa de adquisición de datos

Los datos de vibración empleados en este trabajo fueron obtenidos experimentalmente a partir de una cosechadora *New Holland* modelo *TC56*, con once años de antigüedad y 3800 horas de trabajo. Las señales de vibración fueron adquiridas con la cosechadora operando en modo trilla mientras que las ruedas se encontraban detenidas. Un acelerómetro triaxial

Kistler 8690C50 fue utilizado para medir las señales de vibración en los ejes transversal, longitudinal y vertical (Figura 6). Las señales de vibración fueron adquiridas usando el programa *NI Sound and Vibration Assistant* y un sistema de adquisición de datos (DAQ) de *National Instruments* (NI). El sistema de adquisición de datos se compone de un módulo de adquisición de datos *NI 9234* para señales de entrada analógicas y un chasis compacto *NI cDAQ-9172* para conectar el módulo de adquisición de datos con un ordenador portátil.

Tras varias pruebas mediante ensayo y error, el acelerómetro se colocó en la parte izquierda del chasis de la cosechadora, situado ni muy cerca ni muy lejos de los componentes rotantes analizados. El sensor fue montado usando el método de montaje adhesivo siguiendo las directrices de Scheffer *et al.* [4]. Este método de montaje adhesivo fue seleccionado dado que el análisis frecuencial llevado a cabo en este trabajo está limitado en banda por debajo de 200Hz y este método permite una medición precisa en dicho rango de frecuencias [4].

Figura 6. (a) Esquemático de la cosechadora, donde el símbolo rojo representa el punto del chasis en que fue colocado el acelerómetro, la cruz amarilla representa la ubicación del motor, la cruz azul representa la ubicación del cilindro de la trilla, y la cruz naranja representa la ubicación del picador de paja. (b) Ejes coordenados del acelerómetro en este estudio: el eje x es transversal a la dirección de avance de la cosechadora, el eje y apunta en el sentido opuesto a la dirección de avance de la cosechadora, y el eje z es vertical con respecto al suelo. (c) Montaje experimental para la adquisición de datos con un zoom en la localización del acelerómetro triaxial (*Kistler 8690C50*).



Un total de 18 procesos de adquisición de datos diferentes fueron llevados a cabo en las pruebas experimentales, con el objeto de adquirir suficientes datos en todas las combinaciones de las siguientes condiciones de trabajo de la cosechadora: (i) el estado de velocidad del motor (*máximo/ralentí*); (ii) el estado de operación de la trilla (*on/off*); (iii) el estado de equilibrio de la trilla (*equilibrado/desequilibrado*) mientras la trilla se encontraba encendida; (iv) el


estado de operación del picador de paja (*on/off*); y (*v*) el estado de equilibrio del picador de paja (*equilibrado/desequilibrado*) mientras el picador se encontraba encendido. El picador de paja se desequilibró rompiendo una cuchilla del picador. El desequilibrio se realizó de este modo dado que la ruptura de una cuchilla del picador es una fuente de desequilibrio muy frecuente causada cuando la cuchilla golpea alguna piedra. Por su parte, la trilla se desequilibró añadiendo un peso excéntrico al cilindro de la trilla. El desequilibrio se realizó de este modo porque el cilindro de la trilla puede típicamente ser desequilibrado cuando sus barras sufren de un desgaste no homogéneo debido al uso. Un peso excéntrico produce prácticamente el mismo efecto que dicho proceso de desgaste no homogéneo.

Para cada uno de los 18 procesos de adquisición, épocas o tramas de operación de la máquina de unos sesenta segundos de duración fueron registradas usando una frecuencia de muestreo de 1706.48Hz, obteniendo un total de 99120 muestras por cada época de sesenta segundos de duración.

4.1.2 Etapa de preprocesado

La serie de datos temporal adquirida fue preprocesada, en primera instancia, con el fin de adaptarla para la subsiguiente etapa de extracción de características. La etapa de preprocesado completa fue dividida en las siguientes tres subetapas (Figura 7): (i) subetapa de filtrado paso bajo (*filtering*), (ii) subetapa de diezmado (*downsampling*), y (iii) subetapa de división (*splitting*).

Figura 7. Diagrama de bloques representando las tres subetapas de preprocesado.



En la primera subetapa, un filtrado paso bajo tuvo lugar. Un filtro digital paso bajo IIR elíptico, con una frecuencia de corte de 200Hz, fue aplicado a la señal de entrada. Las frecuencias de vibración de interés, que son los principales armónicos de las velocidades de giro de los componentes mecánicos analizados, se encuentran en el rango que va desde los 0Hz hasta los 200Hz. Este filtrado fue realizado con el fin de eliminar el ruido y las interferencias indeseadas que caían fuera de dicho rango, logrando así un mejor rendimiento del posterior procesado.

Después, tras haber llevado a cabo el filtrado, la subetapa de diezmado tuvo lugar. La señal de entrada fue submuestreada para reducir la frecuencia de muestreo efectiva por un factor N_{fs} , donde $N_{fs} \in \mathbb{N}$ es la tasa de diezmado. En este trabajo un valor de $N_{fs} = 4$ fue escogido, teniendo en cuenta el rango de frecuencias de interés. De esta manera la frecuencia de muestreo efectiva se redujo de 1706.5Hz, la empleada originalmente en la etapa de adquisición, a los 426.625Hz tras el diezmado. Este diezmado permite mantener la información necesaria mientras que simplifica los cálculos posteriores al reducir el número de muestras totales de la señal procesada.

Finalmente, la etapa de división fue llevada a cabo. La señal diezmada, procedente de la segunda subetapa, fue dividida en seis épocas de unos 10 segundos de duración, puesto que este tiempo ha sido considerado como el tamaño suficiente para mantener información significativa acerca de la señal de vibración para los posteriores pasos de extracción de características y para mantener una buena resolución frecuencial en el análisis de la FFT. De este modo, un total de 4130 muestras fueron obtenidas por cada época de diez segundos de duración.

Todas las tareas de preprocesado involucradas en este apartado fueron llevadas a cabo bajo el entorno de programación de *MATLAB*[®].

4.1.3 Etapa de extracción y selección de características

En esta etapa se aborda la reducción de la dimensionalidad de la serie temporal de entrada procedente de la etapa anterior. Ésta se divide en las subetapas de extracción de características y selección de características.

En primer lugar, los datos preprocesados procedentes de la etapa anterior fueron introducidos en la subetapa de extracción de características, con el fin de obtener un clasificador más sencillo. Asumiendo que la señal de entrada a esta etapa se denota por $x[n]$, donde $n = 1, 2, \dots, N = 4130$, las siguientes características fueron extraídas:

- 1) **Average Power (\bar{P}) o potencia media**, definida como $\bar{P} = \frac{1}{N} \sum_{n=1}^N x[n]^2$. Esta característica cuantifica la intensidad global de las vibraciones.
- 2) **Sample Entropy (SampEn) o entropía muestral**, computada usando la definición ofrecida por Richman *et al.* [36]. Esta característica es una medida de la regularidad de la señal que asigna valores mayores a datos más aleatorios, por ejemplo cuando múltiples fuentes de vibraciones se superponen.
- 3) **Spectral Entropy (SpecEn) o entropía espectral**, computada del mismo modo que en el artículo de Hornero *et al.* [30]. Esta

característica ha sido empleada debido a su capacidad de cuantificar la planaridad del espectro. Cuantos más picos tenga la señal, mayor será el valor ofrecido por esta característica.

- 4) **Mean Value (\bar{x}) o valor medio**, calculado como $\bar{x} = \frac{1}{N} \sum_{n=1}^N x[n]$.

Refleja la amplitud de las vibraciones de fondo de baja frecuencia.

- 5) **Median frequency (MF) o frecuencia mediana**, computada como la frecuencia que divide el espectro de potencia en dos mitades que contienen exactamente la misma energía cada una. Fue calculada de la misma manera que en el artículo de Hornero *et al.* [30].

- 6) **Standard Deviation (σ) o desviación estándar**, calculada, utilizando el valor medio \bar{x} previamente definido, como la raíz cuadrada del estimador insesgado de la varianza, i.e. $\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x[n] - \bar{x})^2}$.

Esta característica ofrece información sobre la anchura del histograma de distribución de las amplitudes de vibración, suministrando información adicional acerca de la forma de la señal de vibración.

- 7) **Skewness (s_0) o asimetría estadística**, calculada como el estimador insesgado $s_0 = \frac{\sqrt{N(N-1)}}{N-2} \frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^3}{\left(\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2\right)^{3/2}}$. La asimetría estadística

(*skewness*), siendo una medida de la asimetría del histograma de distribución alrededor de su media, puede reflejar asimetrías de vibración provocadas por fallos mecánicos.

- 8) **Kurtosis (k_0) o curtosis**, calculada como el estimador insesgado $k_0 = \frac{N-1}{(N-2)(N-3)} ((N+1)k_1 - 3(N-1)) + 3$, donde

$$k_1 = \frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^4}{\left(\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2\right)^2}.$$

Esta característica refleja lo picudo que es el histograma, dando información acerca de la distribución de la amplitud de vibración.

- 9) **Central Tendency Measurement (CTM) o medida de la tendencia central**. Primeramente, el diagrama de dispersión de diferencias de primer orden es construido, representando $x[n+1] - x[n]$ en el eje X frente a $x[n+2] - x[n+1]$ en el eje Y. La proporción de puntos que caen dentro de un círculo de determinado radio prefijado es devuelto como medida de la regularidad de la señal. Un radio de 0.05g fue seleccionado en este trabajo, debido a su buena capacidad de separar las clases de clasificación asociadas. Esta característica ofrece una medida de la aleatoriedad de la señal de vibración, donde un valor bajo de esta característica implica cambios abruptos de la señal de vibración. Estos cambios abruptos en la señal de vibración

suelen estar causado tanto por vibraciones de elevada frecuencia como por transiciones repentinas debidas a fallos mecánicos.

10) Correlation coefficient (r) from the first-order differences scatter plot o coeficiente de correlación a partir del diagrama de dispersión de diferencias de primer orden. De manera análoga al

caso de la característica anterior, el diagrama de dispersión de diferencias de primer orden es construido en primer término, obteniendo los vectores $X[n]$ e $Y[n]$. Entonces el coeficiente de correlación lineal de Pearson entre ambos vectores es calculado como:

$$r = \frac{\sum_{n=1}^{N-2} (X[n]-\bar{X})(Y[n]-\bar{Y})}{\sqrt{\sum_{n=1}^{N-2} (X[n]-\bar{X})^2} \sqrt{\sum_{n=1}^{N-2} (Y[n]-\bar{Y})^2}}, \text{ donde } \bar{X} \text{ e } \bar{Y} \text{ son los valores}$$

medios de $X[n]$ e $Y[n]$, respectivamente. Esta característica ofrece una medida de la impredecibilidad de la señal a partir de datos previos, siendo más predecible cuanto mayor sea $|r|$.

11) Lempel-Ziv Complexity (LZC) o complejidad de Lempel-Ziv, computada de la misma manera que en Hornero *et al.* [30]. Esta característica ofrece una noción de complejidad en un sentido estadístico. Caracteriza la cantidad de información media que hay en una señal y, por tanto, puede reflejar la existencia de una superposición de varias fuentes de vibración.

12) Crest Factor (C) o factor de cresta, calculado como $C = \frac{\max_n |x[n]|}{\sqrt{\frac{1}{N} \sum_i x[n]^2}}$,

donde N es el número de muestras de la serie temporal $x[n]$. Esta característica refleja lo escarpada que es una señal con respecto de su valor RMS y, por lo tanto, es útil a la hora de valorar la presencia de fallos mecánicos.

Todos los algoritmos anteriores fueron escogidos basándose en artículo científicos y libros precedentes en la literatura del análisis de vibraciones [18, 51-53] así como extrapolando ideas de otros campos [30, 34, 36].

En segundo lugar, tras haber extraído estas características a partir de la serie temporal preprocesada, la subetapa de selección de características tuvo lugar seleccionando las características más apropiadas de entre todas ellas. El proceso de selección de características fue llevado a cabo usando el método de búsqueda exhaustiva (*Exhaustive Search method*), explorando de este modo todos los 2^{12} posibles subconjuntos de características. Con cada uno de los subconjuntos explorados, se realizó una validación cruzada dejando uno fuera (*leave-one-out cross-validation*), usando un clasificador SVM lineal, para evaluar la bondad de dicho subconjunto en el problema de clasificación. El subconjunto con mayor precisión de validación cruzada (*cross-validation accuracy*) fue seleccionado. El valor del parámetro C , involucrado en el

problema de clasificación SVM, fue prefijado a 1 en todos los casos. La precisión de validación cruzada (*cross-validation accuracy*) se calculó para cada clasificador abordando cada uno de los cinco problemas de clasificación correspondientes a los cinco estados de componentes rotantes contemplados en la cosechadora: (1) el estado de velocidad del motor (*máximo/ralentí*), (2) el estado de funcionamiento de la trilla (*on/off*), (3) el estado de equilibrio de la trilla (*equilibrado/desequilibrado*), (4) el estado de funcionamiento del picador (*on/off*), and (5) el estado de equilibrio del picador (*equilibrado/desequilibrado*).

La elección del método de búsqueda exhaustiva (*Exhaustive Search method*) fue viable debido al relativamente reducido número de características usado, sólo doce como ya se ha comentado antes. En el caso de que un número de características mayor tuvieran que ser exploradas, sería aconsejable emplear el método *Sequential Forward/Backward Floating Search* por motivos de eficiencia computacional [26].

Todas las tareas de esta etapa se han realizado en *MATLAB*[®] usando la biblioteca de *LIBSVM* [54, 55].

4.1.4 Etapa de clasificación basada en SVM

La etapa de clasificación tuvo lugar una vez que las etapas de procesamiento previas habían sido realizadas. Entre la vasta variedad disponible de clasificadores, una clasificación basada en SVM fue utilizada en este trabajo debido a sus buenas propiedades: (i) gran capacidad de generalización, (ii) bajo riesgo de sobre-entrenamiento provocado por conjuntos de entrenamiento pequeños, y (iii) baja carga computacional.

Un clasificador individual diferente se empleó para cada uno de los cinco problemas de clasificación asociados, correspondientes a los siguientes cinco estados de componentes rotantes en la cosechadora: (1) el estado de velocidad del motor (*máximo/ralentí*), (2) el estado de funcionamiento de la trilla (*on/off*), (3) el estado de equilibrio de la trilla (*equilibrado/desequilibrado*), (4) el estado de funcionamiento del picador (*on/off*), and (5) el estado de equilibrio del picador (*equilibrado/desequilibrado*). Cada clasificador recibió como entrada el subconjunto de características que condujo a la máxima *cross-validation accuracy* (Sección 4.1.3). En el caso de que más de un subconjunto condujese al mismo valor máximo, únicamente uno solo de entre ellos se escogió arbitrariamente con el propósito de simplificar la comprensión del trabajo realizado descrito en este documento. Cada clasificador ofrece como salida uno de las dos clases asociadas con el vector de características de entrada.

Para cada uno de los cinco clasificadores SVM, tanto el *kernel* lineal como los *kernels* no lineales *RBF*, *sigmoideal* y *polinómico de tercer grado* fueron

empleados, ofreciéndose una comparativa entre sus precisiones. Estos *kernels* fueron escogidos dado que son los más típicos y ampliamente utilizados. El parámetro C , involucrado en la formulación del problema de clasificación de las SVM, así como los parámetros γ y c_0 , implicados en la función de los *kernels*, fueron optimizados llevando a cabo una búsqueda exponencial en malla sobre dichos parámetros [56]. Los parámetros que dieron lugar a la mayor *cross-validation accuracy* fueron seleccionados como valores óptimos.

El *toolbox* de la biblioteca de *LIBSVM* [54, 55], ejecutándose en *MATLAB*[®], fue nuevamente empleado en las tareas de clasificación.

4.1.5 Etapa de evaluación de rendimiento del clasificador SVM

La precisión de validación cruzada dejando uno fuera (*leave-one-out cross-validation accuracy*) fue explicada en el apartado 2.2. Para cada uno de los cinco problemas de clasificación considerados ésta fue calculada con el fin de evaluar la bondad y precisión del sistema clasificador propuesto. Esas cinco precisiones de validación cruzada (*cross-validation accuracies*), al igual que la precisión media de validación cruzada (*mean cross-validation accuracy*), fueron usados como medida de la precisión del método de estimación basado en SVM de cada uno de los cinco estados de la cosechadora previamente mencionados.

4.2 Resultados

Los resultados experimentales obtenidos en las etapas de selección de características y evaluación de rendimiento del clasificador SVM, explicadas en la Sección 4.1, se presentan en esta sección.

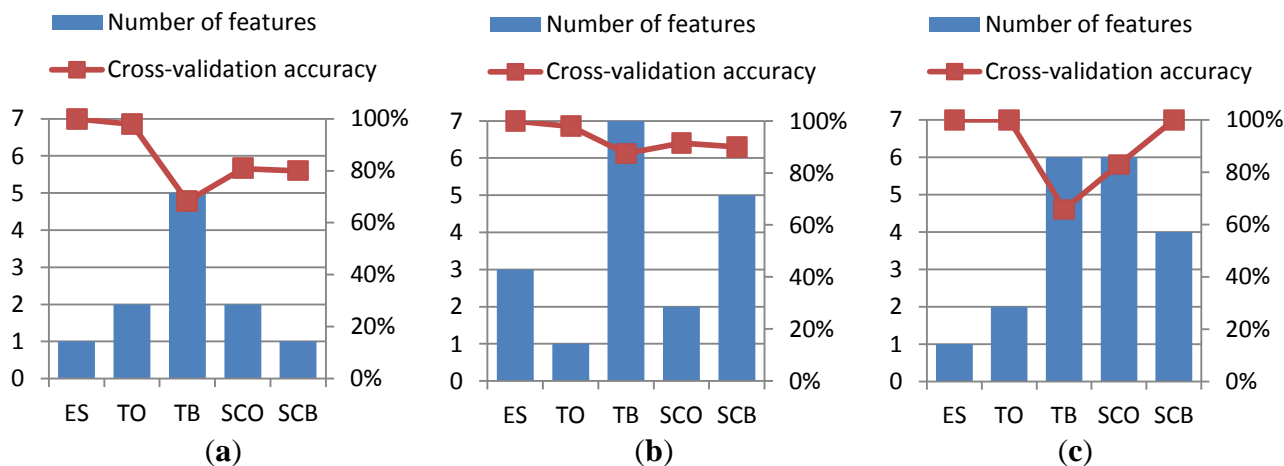
4.2.1 Selección de características

La selección de las mejores características, siguiendo los métodos explicados en el apartado 4.1.3, condujeron a las mejores *cross-validation accuracies* y mejores subconjuntos de características mostrados en la Tabla 1. Se puede apreciar cómo, en todos los casos, el número de características requerido es inferior o igual a siete y que la *cross-validation accuracy* promedio está por encima del 85%, para los tres ejes del acelerómetro. Las mejores *cross-validation accuracies* y el número de características necesario para alcanzarla se representan en la Figura 8.

Tabla 1. Resultados de la selección de características para cada uno de los tres ejes adquiridos por el acelerómetro triaxial. La fila con el número de características muestra el número óptimo requerido para lograr la mejor *cross-validation accuracy*. La fila con el mejor subconjunto de características muestra todos los subconjuntos de características concretos que resultan en la mayor *cross-validation accuracy*, ofrecidos como un listado de números cuya leyenda se corresponde con la lista suministrada en el apartado 4.1.3. Resaltado en negrita se encuentra aquél subconjunto que ha sido empleado en la posterior etapa de evaluación del rendimiento del clasificador (apartado 4.2.2). Cada columna se corresponde con el problema de clasificación asociado a cada componente rotante considerado.

		Classification problem				
		<i>Engine speed</i>	<i>Threshing operating</i>	<i>Threshing balance</i>	<i>Straw chopper operating</i>	<i>Straw chopper balance</i>
Transverse X axis of the accelerometer	Number of features	1	2	5	2	1
	Best features subset(s)	{9}	{10,11}	{4,6,7,9,11}	{2,8};{2,5}	5
	Cross-validation accuracy	100 %	97.87 %	68.29 %	80.85 %	80 %
	Mean CVA	85.40 %				
Longitudinal Y axis of the accelerometer	Number of features	3	1	7	2	5
	Best features subset(s)	{6,7,10}; {5,7,9}; {5,6,10}; {1,6, 10}	{5}	{1,2,7,8,9, 11,12}; {1,2, 4,7,8,11,12}; {1,2,4,6,7, 11,12}; {1,2,3,5,7,8,11}	{4,11}	{1,3,5,7,12}
	Cross-validation accuracy	100 %	97.87 %	87.49 %	91.49 %	90 %
	Mean CVA	93.37 %				
Vertical Z axis of the accelerometer	Number of features	1	2	6	6	4
	Best features subset(s)	{9}	{2,11};{2,3}	{2,3,5,6,8, 11}	{1,4,5,7,8,10}	{1,2,7,10}
	Cross-validation accuracy	100 %	100 %	65.85 %	82.98 %	100 %
	Mean CVA	89.77 %				

Figura 8. Número de características y *cross-validation accuracy* para cada condición de trabajo considerada –(ES) velocidad del motor, (TO) operación de la trilla, (TB) equilibrio de la trilla, (SCO) operación del picador de paja, y (SCB) equilibrio del picador de paja– usando el canal del acelerómetro correspondiente a (a) el eje transversal X, (b) el eje longitudinal Y, y (c) el eje vertical Z.




4.2.2 Evaluación de rendimiento del clasificador SVM

Los resultados de la optimización del clasificador SVM lineal y de los clasificadores no lineales, mostrando las mejores *cross-validation accuracies* y los parámetros óptimos asociados, se detallan en la Tabla 2. Las características previamente seleccionadas, resaltadas en negrita en la Tabla 1, fueron empleadas como entrada al clasificador SVM. Se puede observar que los *kernels* no lineales contemplados no superan al *kernel* lineal en la mayoría de los casos. Incluso en aquellos casos en los que la precisión mejora, únicamente ligeras diferencias se observan, nunca siendo superiores al 10%. Por lo tanto, parece suficientemente preciso emplear clasificación SVM lineal para el problema abordado. Una comparativa entre la *cross-validation accuracy* de los diferentes *kernels* se proporciona también en la Figura 9.

Tabla 2. Resultados de rendimiento para cada uno de los tres ejes del acelerómetro triaxial, comparando los diferentes *kernels* SVM utilizados. Los parámetros optimizados (C , γ , c_0) así como la mejor *cross-validation accuracy* (CVA) son mostrados. El mejor resultado de cada problema de clasificación se resalta en negrita.

		Classification problem					
			<i>Engine speed</i>	<i>Threshing operating</i>	<i>Threshing balance</i>	<i>Straw chopper operating</i>	<i>Straw chopper balance</i>
Transverse X axis of the accelerometer	Linear kernel	CVA	100 %	97.87 %	75.61 %	80.85 %	90.00 %
		C	1	1	6	1	1.2
	Third order polynomial kernel	CVA	100 %	97.87 %	82.93 %	82.98 %	90.00 %
		C	0.03	32768	8192	2048	0.03
		γ	8	0.125	0.125	32	8
		c_0	0.03	0.03	0.5	0.5	0.03
	RBF kernel	CVA	100 %	97.87 %	80.49 %	85.10 %	90.00 %
		C	0.125	512	32	32	0.5
		γ	2	0.125	2	8	2
	Sigmoidal kernel	CVA	100 %	97.87 %	80.49 %	82.98 %	90.00 %
		C	2	2048	2048	8	2
		γ	0.5	0.125	0.125	8	2
c_0		0.03	0.03	0.03	0.5	0.03	
Longitudinal Y axis of the accelerometer	Linear kernel	CVA	100 %	97.87 %	87.49 %	91.49 %	90.00 %
		C	1	1	1	1	1
	Third order polynomial kernel	CVA	100 %	97.87 %	80.49 %	91.49 %	90.00 %
		C	8192	0.03	8192	0.03	2048
		γ	0.125	8	0.002	8	0.125
		c_0	0.03	0.03	8	0.03	0.03
	RBF kernel	CVA	100 %	97.87 %	78.05 %	91.49 %	90.00 %
		C	0.5	0.5	2	2	2
		γ	8	8	0.5	2	2
	Sigmoidal kernel	CVA	100 %	97.87 %	78.05 %	93.62 %	90.00 %
		C	2	32	512	8192	8
		γ	0.5	0.125	0.008	0.125	0.5
c_0		0.03	0.03	0.03	0.125	0.03	
Vertical Z axis of the accelerometer	Linear kernel	CVA	100 %	100 %	65.85 %	85.10 %	100 %
		C	1	1	1	430	1
	Third order polynomial kernel	CVA	100 %	100 %	63.41 %	89.36 %	100 %
		C	8192	512	2048	8192	0.03
		γ	0.125	0.5	0.125	0.03	8
		c_0	0.03	0.03	0.5	2	0.03
	RBF kernel	CVA	100 %	100 %	68.29 %	87.23 %	100 %
		C	0.125	32	2	8192	2
		γ	2	0.5	32	0.03	0.5
	Sigmoidal kernel	CVA	100 %	100 %	63.41 %	82.97 %	100 %
		C	2	128	512	32	8
		γ	0.5	0.125	0.5	0.125	0.5
c_0		0.03	0.03	0.125	0.03	0.03	

Figura 9. *Cross-validation accuracy* para cada *kernel* bajo las condiciones de trabajo consideradas –(*ES*) velocidad del motor, (*TO*) operación de la trilla, (*TB*) equilibrio de la trilla, (*SCO*) operación del picador de paja, y (*SCB*) equilibrio del picador de paja– usando el canal del acelerómetro correspondiente a **(a)** el eje transversal X, **(b)** el eje longitudinal Y, y **(c)** el eje vertical Z.



COMPARATIVA CON TRABAJOS PREVIOS

En este trabajo se investiga sobre la estimación del estado de múltiples componentes rotantes en maquinaria agro-industrial procesando señales de vibración adquiridas a partir de un único punto de la estructura de la máquina. En relación a este estudio, tres hallazgos se han encontrado.

El primer hallazgo de este trabajo es que es posible estimar de manera precisa el estado de múltiples componentes rotantes de maquinaria agro-industrial procesando la señal de vibración adquirida en un único punto de la estructura de la máquina. Además, el sensor de medida (acelerómetro) no necesita ser colocado muy cerca de los componentes mecánicos analizados, lo cual hace no intrusiva y más simple la etapa de adquisición de datos. Los resultados presentados previamente revelan el potencial de estimar el estado de componentes alejados procesando señales de vibración de un único sensor ubicado en un punto intermedio del chasis de la cosechadora (Figura 6), dado que se obtuvo una *mean cross-validation accuracy* superior al 85%. Trabajos previos en la literatura científica han sido llevado a cabo, pero sólo analizando componentes mecánicos aislados, usando un acelerómetro para cada componente analizado que además se encontraba aislado del resto de componentes de la maquinaria [13, 18, 53]. Merece la pena reseñar que, hasta donde alcanza nuestro conocimiento, ningún artículo previo ha abordado el problema de estimar el estado de múltiples componentes mecánicos a partir de una única señal de vibración.

El segundo hallazgo de este trabajo es que la señal de vibración puede ser adquirida con un acelerómetro uniaxial cuya orientación no afecta

significativamente la precisión de la estimación. La comparativa llevada a cabo entre los resultados de *cross-validation accuracy* de los tres ejes del acelerómetro (Tabla 2) apoyan esta conclusión. Las mayores diferencias observadas en la Tabla 2 se encuentran en el estado de equilibrio de la trilla, para el cual diferencias de alrededor de un 20% se pueden apreciar. No obstante, prácticamente ninguna diferencia se puede apreciar para el resto de los estados, siendo inferiores al 10% en cualquier otro caso. Aunque las vibraciones habitualmente se generan en una dirección específica, los resultados aquí obtenidos sugieren que la estructura de la máquina distribuye dicha vibración a lo largo de todos los ejes, haciendo de esta manera posible el uso de un eje arbitrario para poder detectar dichas vibraciones.

El tercer hallazgo de este trabajo es que, cuando se emplea un clasificador SVM, una *cross-validation accuracy* promedio del 85% se puede lograr requiriendo nada más de siete características de entrada a lo sumo, y además no se aprecian mejoras significativas al emplear *kernels* no lineales con respecto a usar un *kernel* lineal. Echando un vistazo a los resultados de este trabajo, una *cross-validation accuracy* promedio mayor que el 85% fue lograda con independencia del eje del acelerómetro seleccionado. Analizando la *cross-validation accuracy* individual obtenida para cada componente rotante, la adecuación del clasificador basado en SVM para estimar el estado de cada componente de la maquinaria por separado resulta evidente. Por un lado, el estado del componente rotante con la mejor *cross-validation accuracy* fue la velocidad del motor, con una *cross-validation accuracy* del 100% en todos los casos (Tabla 2). Por otro lado, la peor *cross-validation accuracy* se obtuvo para el caso del estado de equilibrio de la trilla, para la cual la *cross-validation accuracy* osciló entre un 63.41% y un 87.49% (Tabla 2). Analizando de manera visual el espectro de las señales de vibración, existen diferencias cuando la velocidad del motor se varía entre ralentí y máximo, mientras que por su parte no hay cambios apreciables en el espectro de la señal cuando la trilla se halla equilibrada o desequilibrada. Estos resultados muestran que el clasificador SVM propuesto es capaz de clasificar el estado de maquinaria rotante con un elevado grado de precisión cuando las diferencias del espectro de las señales es apreciable, tales como en el caso de la velocidad del motor. Los resultados también muestran que se puede obtener una *cross-validation accuracy* aceptable para aquellos componentes rotantes para los que no existen diferencias visibles entre los espectros de sus dos posibles estados, tales como en el caso del estado de equilibrio de la trilla.

Comparando las precisiones en la detección de fallos frente a los resultados de Samanta *et al.* [53], quienes propusieron un clasificador basado en ANN para el diagnóstico de fallos de rodamientos de bolas basándose en los datos

obtenidos de varias señales de vibración extrayendo cinco características en el dominio temporal, el presente trabajo ha obtenido unos resultados un poco más pobres. Sin embargo, estas diferencias se pueden justificar teniendo en cuenta que en el artículo de Samanta *et al.* cinco señales de vibración de diferentes puntos de un único componente fueron procesadas y también debido a que dichas señales estaban limpias, en tanto en que procedían tan sólo del componente mecánico bajo análisis aislado. Por su parte, en el presente trabajo un único acelerómetro es utilizado para detectar cinco estados de tres componentes rotantes diferentes y, además, la señal de vibración procesada contiene superpuestas las señales procedentes de los tres componentes analizados así como de otros componentes de la máquina. Como se puede entender de manera evidente, el presente trabajo aborda un problema considerablemente más complejo.

La principal fortaleza del sistema propuesto en este trabajo radica en la simplicidad de la etapa de adquisición de datos, que emplea tan solo un único sensor localizado en un punto para medir las señales de vibración. Merece la pena resaltar el artículo de Sugumaran *et al.* [18], quienes propusieron un clasificador basado en SVM para el diagnóstico de fallos de un único rodamiento de bolas empleando tan sólo una señal de vibración. Nuestro estudio, aunque similar al de Sugumaran *et al.*, es más amplio en el sentido de intentar evaluar a la vez el estado de varios componentes rotantes de maquinaria en lugar de tan solo un componente. Además, el presente trabajo contempla la detección de un número mayor de estados de la maquinaria, no sólo el diagnóstico de fallos.

Otra fortaleza de este trabajo es que el método de estimación propuesto sólo necesita, como mucho, siete características como entrada al clasificador, produciendo un clasificador SVM simple y con una baja carga computacional asociada. Adicionalmente, los resultados no mostraban grandes diferencias con respecto del *kernel* SVM empleado. Este hecho pone de manifiesto que un clasificador SVM lineal, que es más sencillo, es suficiente para lograr una buena precisión de clasificación.

Con todo y con ello, este trabajo presenta alguna limitación que debe ser considerada antes de implementar el método de estimación propuesto. La principal limitación está ligada al proceso de adquisición de datos llevado a cabo en este trabajo para validar el sistema propuesto basado en SVM. Las señales de vibración fueron adquiridas con las ruedas de la cosechadora paradas para facilitar el procedimiento de adquisición. Si el método de estimación propuesto se fuera a emplear cuando la máquina monitorizada se encuentra en movimiento, cosa más que deseable y probable, podrían

aparecer señales de interferencia de baja frecuencia. No obstante, es de esperar que no causen excesivos problemas dado que las frecuencias de interés de los componentes rotantes de estas máquinas van a ser con toda seguridad mucho mayores que las frecuencias de interferencia. Otra limitación, también ligada en este caso al montaje de las pruebas experimentales, son los malos resultados obtenidos para el caso del equilibrio de la trilla, que sugieren que el desequilibrio producido era demasiado pequeño para poder ser discriminado.

CONCLUSIONES Y LÍNEAS FUTURAS

6.1 Conclusiones

Los resultados obtenidos en este estudio aportan evidencias de que (i) es posible estimar con precisión el estado de múltiples componentes rotantes de maquinaria agro-industrial procesando la señal de vibración adquirida de un único punto de la estructura de la máquina; (ii) la señal de vibración se puede adquirir mediante un acelerómetro uniaxial cuya orientación no afecta de manera significativa a la precisión de clasificación; y (iii) cuando se usa un clasificador basado en SVM, una *mean cross-validation accuracy* del 85% se puede conseguir empleando como entrada tan solo siete características, a lo sumo, y además no se apreciaron mejoras significativas al utilizar *kernels* no lineales con respecto a utilizar un *kernel* lineal. La aplicación del presente estudio puede conducir a una simplificación del cableado y a una reducción en el número de sensores requeridos en la monitorización de maquinaria, así como a inspecciones de maquinaria rápidas y de bajo coste en relación con el mantenimiento predictivo.

6.2 Líneas futuras

Los principales campos de aplicación del sistema propuesto basado en SVM son la monitorización de maquinaria (*machinery monitoring*) y el mantenimiento predictivo (*predictive maintenance*). En relación a *machinery monitoring*, este sistema podría ser usado para detectar el estado de operación de componentes mecánicos particulares, simplificando el cableado y reduciendo el número de sensores requeridos. En relación a *predictive maintenance*, los

resultados sugieren que nuevos avances adicionales del presente estudio pueden conducir a inspecciones de maquinaria rápidas y de bajo coste, evitándose así muchos fallos mecánicos y las inspecciones que hoy en día son caras y consumen mucho tiempo.

Una mezcla tanto de características clásicas en el análisis de vibraciones, como las características basadas en el dominio de la frecuencia [4, 6, 13, 18, 24, 31] y en el dominio del tiempo [51-53], como de otras características poco convencionales en este campo, como las características no lineales [30, 34, 36], han sido empleadas en este trabajo. Las buenas y prometedoras tasas de acierto obtenidas en este trabajo, por ejemplo las obtenidas con la característica *Central Tendency Measurement* al estimar el estado de velocidad del motor (Tabla 1), pone de relieve la utilidad de las características no convencionales en el análisis de vibraciones para el mantenimiento predictivo. Una línea futura se abre para que posteriores investigaciones empleen éstas y otras características no convencionales en el análisis de vibraciones para el mantenimiento predictivo.

A mayores, este trabajo abre una nueva línea futura de investigación, extendiendo el sistema aquí propuesto empleando más de un acelerómetro ubicado en diferentes puntos de la máquina. Se espera que el procesamiento de dichas señales en conjunto podría habilitar la estimación de un número incluso mayor de estados de la máquina y podría también mejorar la precisión de la estimación.

Otra posible línea futura que deja abierta este trabajo es la posibilidad de modificar el procesado de manera que se consideren los tres ejes del acelerómetro triaxial de manera conjunta, como si de un vector tridimensional se tratara. Cabe esperar que este uso conjunto mejore la precisión de los resultados aquí obtenidos.

BIBLIOGRAFÍA

1. Martin, K. F., A review by discussion of condition monitoring and fault diagnosis in machine tools. *Int. J. Mach. Tools Manuf.* **1994**, 34(4), 527-551.
2. Jardine, A. K. S.; Lin, D.; Banjevic, D., A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech. Syst. Signal Proc.* **2006**, 20(7), 1483-1510.
3. Girdhar, P.; Scheffer, C., 8 - Other predictive maintenance techniques. In *Practical Machinery Vibration Analysis and Predictive Maintenance*, Girdhar, P.; Scheffer, C., Eds. Newnes: Oxford, 2004; pp 221-234.
4. Scheffer, C.; Girdhar, P., *Practical Machinery Vibration Analysis and Predictive Maintenance*. Newnes: Oxford, 2004.
5. Wang, W. Q.; Ismail, F.; Farid Golnaraghi, M., Assessment of Gear Damage Monitoring Techniques Using Vibration Measurements. *Mech. Syst. Signal Proc.* **2001**, 15(5), 905-922.
6. Peng, Z. K.; Chu, F. L., Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mech. Syst. Signal Proc.* **2004**, 18(2), 199-221.
7. Li, Z.; Yan, X.; Tian, Z.; Yuan, C.; Peng, Z.; Li, L., Blind vibration component separation and nonlinear feature extraction applied to the nonstationary vibration signals for the gearbox multi-fault diagnosis. *Measurement* **2013**, 46(1), 259-271.
8. Albarbar, A.; Gu, F.; Ball, A. D., Diesel engine fuel injection monitoring using acoustic measurements and independent component analysis. *Measurement* **2010**, 43(10), 1376-1386.
9. Taghizadeh-Alisaraei, A.; Ghobadian, B.; Tavakoli-Hashjin, T.; Mohtasebi, S. S., Vibration analysis of a diesel engine using biodiesel and petrodiesel fuel blends. *Fuel* **2012**, 102, 414-422.
10. Vulli, S.; Dunne, J. F.; Potenza, R.; Richardson, D.; King, P., Time-frequency analysis of single-point engine-block vibration measurements for multiple excitation-event identification. *J. Sound Vibr.* **2009**, 321(3-5), 1129-1143.
11. Wang, X.; Makis, V.; Yang, M., A wavelet approach to fault diagnosis of a gearbox under varying load conditions. *J. Sound Vibr.* **2010**, 329(9), 1570-1585.
12. Bin, G. F.; Gao, J. J.; Li, X. J.; Dhillon, B. S., Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network. *Mech. Syst. Signal Proc.* **2012**, 27, 696-711.
13. Cheng, G.; Cheng, Y.-l.; Shen, L.-h.; Qiu, J.-b.; Zhang, S., Gear fault identification based on Hilbert–Huang transform and SOM neural network. *Measurement* **2013**, 46(3), 1137-1146.
14. McFadden, P. D.; Cook, J. G.; Forster, L. M., Decomposition of Gear Vibration Signals by the Generalised S Transform. *Mech. Syst. Signal Proc.* **1999**, 13(5), 691-707.
15. Wang, Y. S.; Ma, Q. H.; Zhu, Q.; Liu, X. T.; Zhao, L. H., An intelligent approach for engine fault diagnosis based on Hilbert–Huang transform and support vector machine. *Appl. Acoust.* **2014**, 75, 1-9.

16. Lei, Y.; Lin, J.; He, Z.; Zuo, M. J., A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mech. Syst. Signal Proc.* **2013**, 35(1–2), 108-126.
17. Li, Y.; Tse, P. W.; Yang, X.; Yang, J., EMD-based fault diagnosis for abnormal clearance between contacting components in a diesel engine. *Mech. Syst. Signal Proc.* **2010**, 24(1), 193-210.
18. Sugumaran, V.; Ramachandran, K. I., Effect of number of features on classification of roller bearing faults using SVM and PSVM. *Expert Syst. Appl.* **2011**, 38(4), 4088-4096.
19. Vapnik, V. N., *Statistical Learning Theory*. Wiley: New York, 1998; p 736.
20. Moguerza, J. M.; Muñoz, A., Support Vector Machines with Applications. *Statist. Sci.* **2006**, 21(3), 322-336.
21. Joachims, T., *Learning to Classify Text using Support Vector Machines: Methods, Theory and Algorithms*. Kluwer Academic Publishers: 2002; p 205.
22. Wu, C.-H.; Ho, J.-M.; Lee, D. T., Travel-time prediction with support vector regression. *IEEE Trans. Intell. Transp. Syst.* **2004**, 5(4), 276 - 281.
23. Su, H.; Shi, T.; Chen, F.; Huang, S., New method of fault diagnosis of rotating machinery based on distance of information entropy. *Frontiers of Mechanical Engineering* **2011**, 6(2), 249-253.
24. Dai, J.; Chen, C. L. P.; Xu, X.-Y.; Huang, Y.; Hu, P.; Hu, C.-P.; Wu, T., Machinery Vibration Signals Analysis and Monitoring for Fault Diagnosis and Process Control. In *Advanced Intelligent Computing Theories and Applications. With Aspects of Theoretical and Methodological Issues*, Huang, D.-S.; Wunsch, D., II; Levine, D.; Jo, K.-H., Eds. Springer Berlin Heidelberg: 2008; Vol. 5226, pp 696-703.
25. Widodo, A.; Yang, B.-S., Support vector machine in machine condition monitoring and fault diagnosis. *Mech. Syst. Signal Proc.* **2007**, 21(6), 2560-2574.
26. Jain, A. K.; Duin, R. P. W.; Mao, J., Statistical pattern recognition: a review. *IEEE Trans. Pattern Anal. Mach. Intell.* **2000**, 22(1), 4-37.
27. Kotsiantis, S. B., Supervised Machine Learning: A Review of Classification Techniques. *Informatica* **2007**, 31, 249-268.
28. Doğanaksoy, A.; Göloğlu, F., On Lempel-Ziv Complexity of Sequences. In *Sequences and Their Applications – SETA 2006*, Gong, G.; Hellesteth, T.; Song, H.-Y.; Yang, K., Eds. Springer Berlin Heidelberg: 2006; Vol. 4086, pp 180-189.
29. Vanluchene, A. L.; Vereecke, H.; Thas, O.; Mortier, E. P.; Shafer, S. L.; Struys, M. M., Spectral entropy as an electroencephalographic measure of anesthetic drug effect: a comparison with bispectral index and processed midlatency auditory evoked response. *Anesthesiology* **2004**, 1(101), 34-42.
30. Hornero, R.; Escudero, J.; Fernandez, A.; Poza, J.; Gomez, C., Spectral and Nonlinear Analyses of MEG Background Activity in Patients With Alzheimer's Disease. *IEEE Trans. Biomed. Eng.* **2008**, 55(6), 1658 - 1665.
31. GuoHua, G.; Yu, Z.; Guanghuang, D.; Yongzhong, Z., Intelligent Fault Identification Based On Wavelet Packet Energy Analysis and SVM. In *Control, Automation, Robotics and Vision, 2006. ICARCV '06. 9th International Conference on*, Singapore, 5-8 Dec. 2006 pp 1-5.

32. Grassberger, P.; Procaccia, I., Measuring the strangeness of strange attractors. *Physica D* **1983**, 9(1-2), 189-208.
33. Li, M.; Vitányi, P., *An Introduction to Kolmogorov Complexity and Its Applications*. 3rd ed.; 2008; p 792.
34. Aboy, M.; Hornero, R.; Abásolo, D.; Álvarez, D., Interpretation of the Lempel-Ziv complexity measure in the context of biomedical signal analysis. *IEEE Trans. Biomed. Eng.* **2006**, 53(11), 2282-2288.
35. Pincus, S. M., Approximate entropy as a measure of system complexity. *Proc. Natl. Acad. Sci. U. S. A.* **1991**, 88(6), 2297-2301.
36. Richman, J. S.; Moorman, J. R., Physiological time-series analysis using approximate entropy and sample entropy. *Am. J. Physiol.-Heart Circul. Physiol.* **2000**, 278(6), H2039-H2049.
37. Aggarwal, N.; Agrawal, R. K., First and Second Order Statistics Features for Classification of Magnetic Resonance Brain Images. *Journal of Signal and Information Processing* **2012**, 3(2), 146-153.
38. Zhou, B.-H.; Liu, P.; Liu, N. B.; Wu, X. H.; Lu, R.; Ni, X. M., Median frequency of surface EMG signal of antagonist muscles during repeated contractions. In *Engineering in Medicine and Biology Society, 1992 14th Annual International Conference of the IEEE Paris*, Oct. 29 1992-Nov. 1 1992 Vol. 4, pp 1626-1627.
39. Wang, X.; Paliwal, K. K., Feature Extraction and Dimensionality Reduction Algorithms and Their Applications in Vowel Recognition. *Pattern Recognit.* **2003**, 36, 2429-2439.
40. Cortes, C.; Vapnik, V., Support-vector networks. *Mach. Learn.* **1995**, 20(3), 273-297.
41. Haykin, S., *Neural Networks: A Comprehensive Foundation*. 2nd ed.; Prentice Hall PTR: New Jersey, USA, 1998; p 842.
42. Ren, J., ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. *Knowledge-Based Syst.* **2012**, 26, 144–153.
43. Hsu, C.-W.; Lin, C.-J., A comparison of methods for multiclass support vector machines. *IEEE Trans. Neural Netw.* **2002**, 13(2), 415-425.
44. Ferris, M. C.; Munson, T. S., Interior-point methods for massive support vector machines. *SIAM J. Optim.* **2006**, 13, 783-804.
45. Platt, J. C. *Sequential minimal optimization: A fast algorithm for training support vector machines*; Microsoft Research: Abril 1998.
46. Platt, J. C., Chapter 12: Fast training of support vector machines using sequential minimal optimization. In *Advances in Kernel Methods: Support Vector Learning*, 1st ed.; Schölkopf, B.; Burges, C. J. C.; Smola, A. J., Eds. MIT Press: Cambridge, 1998.
47. Shilton, A.; Palaniswami, M.; Ralph, D.; Tsoi, A. C., Incremental training of support vector machines. *IEEE Trans. Neural Netw.* **2005**, 16(1), 114-131.
48. Campbell, C.; Cristianini, N. *Simple learning algorithms for training support vector machines*; University of Bristol: 1998.
49. Campbell, C.; Ying, Y., *Learning with Support Vector Machines*. 1st ed.; Morgan & Claypool Publishers: San Rafael, CA, 2011.
50. Steinwart, I.; Christmann, A., *Support Vector Machines*. 1st ed.; Springer Publishing Company, Inc.: 2008.

51. Norton, M. P.; Karczub., D. G., *Fundamentals of Noise and Vibration Analysis for Engineers*. Cambridge University Press: 2003.
52. Tandon, N., A comparison of some vibration parameters for the condition monitoring of rolling element bearings. *Measurement* **1994**, 12(3), 285-289.
53. Samanta, B.; Al-Balushi, K. R., Artificial Neural Network based fault diagnostics of rolling element bearings using time-domain features. *Mech. Syst. Signal Proc.* **2003**, 17(2), 317-328.
54. Chang, C.-C.; Lin, C.-J., LIBSVM: A library for support vector machines. *ACM Trans. Intell. Syst. Technol.* **2011**, 2(3), 27:1-27:27.
55. Chang, C.-C.; Lin, C.-J. LIBSVM - A Library for Support Vector Machines. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm> (accessed on August 3, 2014)
56. Hsu, C.-W.; Chang, C.-C.; Lin, C.-J. *A Practical Guide to Support Vector Classification*; Department of Computer Science and Information Engineering, National Taiwan University: 2010.

ANEXO I: ARTÍCULO ENVIADO

MANUSCRITO DEL ARTÍCULO ENVIADO

Revista científica: *Sensors*

Factor de impacto: 2.048 (*Journal Citation Report ISI*) (2013)

Área: *Instruments & Instrumentation*

Posición: #10/57 (*Q1*)

Article

A SVM-based classifier for detecting the state of multiple rotating components in agro-industrial machinery using a vibration signal acquired from a single point of the machine chassis

Ruben Ruiz-Gonzalez ¹, Jaime Gomez-Gil ^{1,*}, Francisco Javier Gómez-Gil ² and Víctor Martínez-Martínez ¹

¹ Department of Signal Theory, Communications and Telematics Engineering, University of Valladolid, 47011 Valladolid, Spain; E-Mails: rruigon@ribera.tel.uva.es, vmarmar@ribera.tel.uva.es

² Department of Electromechanical Engineering, University of Burgos, 09006 Burgos, Spain; E-Mail: fjggil@ubu.es

* Author to whom correspondence should be addressed; E-Mail: jgomez@tel.uva.es; Tel.: +34-617507469; Fax: +34-983423667

Received: / Accepted: / Published:

Abstract:

The goal of this article is the assessment of the capability of predicting the status of multiple rotating components in agro-industrial machinery by just employing a vibration signal acquired from a single point in the chassis of the machine. For this end a SVM-based classifying system is proposed. In order to evaluate this system, experimental tests were conducted by acquiring vibration data from a single point of an agricultural harvester varying on it several working conditions. Making use of the vibration data, the whole involved processing included two main steps. Initially, the acquired vibration data were preprocessed through twelve feature extraction algorithms, then selecting the most suitable features by means of the *Exhaustive Search* method. Secondly, the SVM-based classifying system accuracy was evaluated using *Leave-One-Out* cross-validation, using the selected features as input. The results obtained in this study give evidence that (i) it is possible to accurately estimate the status of some rotating components in agro-industrial machinery by processing the vibration signal acquired from a single point of the machine structure; (ii) the vibration signal can be acquired with an uniaxial accelerometer whose orientation does

not significantly affect the accuracy of the classification; and (iii) when using a SVM classifier, a 85% mean cross-validation accuracy can be reached only requiring as input seven features at most, and no significant improvements are noticed from using nonlinear kernels with respect to using a linear kernel.

Keywords: *Support Vector Machine* (SVM), predictive maintenance (PdM), agricultural machinery, condition monitoring, fault diagnosis, vibration analysis, feature extraction and selection, pattern recognition.

1. Introduction

Agro-industrial machinery are costly devices which require a frequent maintenance in order to avoid further expenses in repairing tasks [1]. The necessity and goodness of a planned machine maintenance is a well argued topic in industry as well as in the related academic research literature [2]. An early detection of the malfunctioning of a mechanical component allows its promptly replacement, thus avoiding costly future reparations.

Nowadays, many machinery predictive maintenance techniques are employed in order to reduce hazards and subsequent failures [1-3]. The main such techniques, according to Scheffer *et al.* [4], are vibration monitoring, acoustic emission, oil analysis, particle analysis, corrosion monitoring, thermography, and performance monitoring.

Vibration analysis is a non-intrusive method widely employed in machinery status inspections, mainly on rotating equipment including engines, turbines, and compressors, among others [4-6]. In the cases of machinery in which no vibration isolation is applied, the vibration signal propagates through the whole structure of the machine with moderate attenuation. This fact makes possible to monitor some rotating components placing an accelerometer in another position of the machine structure [7]. However, this propagation capability has also the disadvantage of having other vibration signals, from other components of the structure, added to the signal of interest, making more difficult the extraction of the relevant information [8].

Vibration signals from rotating components are commonly analyzed in the frequency domain because significant peaks in the signal spectrum appear at frequencies which present a relationship with the rotation frequency of the component [4]. Some authors have performed this analysis using the fast Fourier transform [9], the short time Fourier transform [10], the wavelet transform [11-13], the S-transform [14], or the Hilbert-Huang transform [13, 15-17], among others. Due to the relationship between the rotation frequency of the machine component and the greatest peaks in the spectrum signal, expert people can estimate the status of machine components looking for patterns in the spectrum signal. Nevertheless, doing so requires the analysis of the vibration signal spectrum by an expert person who must hold detailed knowledge of the machine functioning as well as full information about the rotating speed of the component. Automated systems have been proposed to estimate the status of machine components using frequency analysis without requiring an expert [13,

18]. These systems incorporate the knowledge about the machine component to extract characteristics from the spectrum signal and to estimate the status according to these characteristics.

Support Vector Machine (SVM) [19] is a supervised learning model widely used in the discipline of pattern recognition for classifying purposes. Due to its learning and generalization capabilities it is well suited for the implementation of estimation methods, which are widely required in automated diagnosis systems. According to the literature, many SVM-based applications have been successfully implemented [20], both for classification [21] and nonlinear regression [22]. Focusing specifically in the field of vibration monitoring in machinery fault diagnosis, many improvements have been made in the recent years [23, 24]. Widodo and Yang [25] offered a very complete review of the latest major advances in the field of SVM-based vibration analysis for predictive maintenance.

Although a good deal of research works have previously made use of SVMs in machinery predictive maintenance [18, 25], to the best of our knowledge, automatic prediction of the state of multiple rotating components of a whole agro-industrial machine employing just a vibration signal acquired from a single point in the chassis of the machine has not been conducted in previous researches so far.

The goal of this article is performing a proof of concept for the assessment of the capability of predicting the state of multiple rotating components in agro-industrial machinery, by just employing as system input a vibration signal acquired from a single point in the chassis of the machine. In order to evaluate that prediction capability, the following five rotating component states in an agricultural harvester were considered: (1) the engine speed status (*high speed/low speed*), (2) the threshing operating status (*on/off*), (3) the threshing balance status (*balanced/unbalanced*), (4) the straw chopper operating status (*on/off*), and (5) the straw chopper balance status (*balanced/unbalanced*).

2. Background

This section comprises some fundamentals about vibration analysis in agro-industrial machinery, classification in supervised machine learning, feature extraction and selection, and SVM-based classification.

2.1. Vibrations in agro-industrial machinery

Vibrations can be defined as the motion of a certain point back and forth from its position of rest. The most popular devices used for capturing vibration signals in rotating machinery applications are accelerometers. An accelerometer is a sensor which measures proper acceleration. Typical accelerometers capture signals in frequency ranges from 1 Hz to 10 kHz [4].

The most common defects causing high vibration levels in machinery, in accordance with Scheffer *et al.* [4], are: unbalance of rotating parts, misalignment of couplings and bearings, bent shafts, worn or damaged gears and bearings, bad drive belts and chains, torque variations, electromagnetic forces, aerodynamic forces, hydraulic forces, looseness, rubbing, and resonance. When machinery rotating components operate at high speeds or under harsh operating conditions for a long time, some of these defects start to appear.

Vibrations can reveal the presence of machinery defects. Usually, vibrations on rotating components appear at specific frequencies, which are characteristic of each specific component and also depend on the component rotating speed and other properties [13, 18]. Traditionally, depending on the vibration amplitude at those specific frequencies, the severity of the defects can be assessed. Thus, plenty of information about the condition of a component, e.g. a possible deterioration, can be detected by analyzing the vibration characteristics of isolated components [4].

In addition, vibration signals from a specific machinery component can be acquired at a distant point of the machine structure, though slightly attenuated, due to the propagation capability of the machine structure as well as the imperfect isolation of the main sources of vibration. This propagation ability makes way more difficult the processing to extract useful information, because of the mixing of information from several machinery components, but it simplifies the data acquisition stage, limiting the installation of sensors just to a single point of the machine.

2.2. Classification in supervised machine learning

Machine learning, as a subfield of artificial intelligence in computer science, deals with systems that can learn from data, modifying its behavior depending on its input data. In order to learn from data, typically the system must have the capability of deducing the function underlying the input data. Machine learning can be divided in unsupervised and supervised learning, depending on what information is available for the learning process. Unsupervised machine learning undertakes the inference process using an unlabeled training set, i.e. without any information about the desired output, and tries to deduce relationships by looking for similarities in the dataset. Meanwhile, supervised machine learning assumes that a labeled training set, for which the desired output is completely known, is available.

Classification, as a branch of supervised learning, is defined as the process of identifying the class to which a previously unseen observation belongs, based on previous knowledge given by a training dataset that contains instances whose category membership is fully known. Any algorithm which performs classification tasks, i.e. the mapping of input data to an assigned class, is called a classifier.

Classifiers must be trained, based on previous knowledge, in order to function properly. The training process makes use of a sample of N observations, for which their corresponding classes are fully known. This sample of N observations is typically divided into two subsamples: the training and test datasets. Firstly, the training dataset is used in the process of computing a classifier well-adapted to these data. Then the test dataset is used to assess the generalization capability of the previously computed classifier.

In order to assess the performance of a classifier, the misclassification rate or success rate in the test dataset are commonly used as a quality measurement. Misclassification rate is defined as the proportion of observations which are wrongly assigned to an incorrect class, and it is calculated as the following quotient:

$$MR = \frac{\text{Number of Incorrect Classifications}}{\text{Total Number of Classifications}}$$

Alternatively, the hit rate or success rate is defined as the proportion of observations which are properly assigned to the corresponding class, and it is calculated as the following quotient:

$$SR = \frac{\text{Number of Correct Classifications}}{\text{Total Number of Classifications}} = 1 - MR$$

An enhanced way of evaluating the performance of a classifier, especially when the training and test datasets are small, is using *k-fold cross-validation*. In *k-fold cross-validation*, the original sample of N observations is randomly partitioned into k subsamples of equal size. From those k subsamples, a single subsample is retained as the test dataset, and the remaining $k - 1$ subsamples are used as training dataset. The *k-fold cross-validation* repeats this training and test process k times, using each of the k subsamples exactly once as test dataset. Cross-validation accuracy is calculated as the average of the success rate obtained for each of the k different test datasets. When $k=N$, the *k-fold cross-validation* is also known as *leave-one-out cross-validation*.

Many different classifiers have been proposed in the literature so far [26, 27]. Some of the main such classifiers include *k-nearest neighbor classifier*, *Bayes classifier*, *logistic regression*, *Fisher's linear discriminant*, *decision tree*, *Artificial Neural Networks (ANN)*, and *Support Vector Machines (SVM)*. A SVM classifier is used later along this article, and therefore SVM is covered more in detail in Subsection 2.4.

2.3. Feature extraction and selection for classification

Machine learning systems, including classifiers, are typically required to process much information. A way to avoid the classifier processing too much data and improve its performance is by applying dimensionality reduction techniques to the input data. Dimensionality reduction, within statistical machine learning field, is defined as the process of reducing the number of variables of a dataset while retaining most of its degrees of freedom, thereby simplifying the subsequent classification problem. Feature extraction and selection are methods to accomplish dimensionality reduction.

Feature extraction [26] is a technique that consists in reducing the dimensions of a d -dimensional input data vector, transforming it into a new m -dimensional output data vector, where $m < d$. The resulting m -dimensional vector, called feature vector, should retain from the original vector most of the useful information for the subsequent classification stage. This property is often referred as *degrees of freedom preservation*. Attending to their data type, features can be categorical, ordinal, integer-valued, or real-valued. A very wide variety of feature extraction algorithms have been proposed in the literature [28-31]. A possible taxonomy of these algorithms can be made based on their relationship to specific mathematical fields. The most popular such categories are nonlinear, statistical and transformed-domain based. Some of the nonlinear feature extraction algorithms are *Correlation Dimension* [32], *Kolmogorov Complexity* [33], *Lempel-Ziv Complexity* [28, 34], *Approximate Entropy* [35], and *Sample Entropy* [36]. Classical time-domain based methods of statistical feature extraction include *Mean Value*, *Standard Deviation*, *Skewness*, *Kurtosis*, *Average Power*, and *Shannon Entropy* [37]. Remarkable techniques of frequency domain feature extraction are *Spectral Entropy* [29], *Median Frequency* [30, 38], *Bandwidth Containing 90% of the Signal Energy*, and *Relative Wavelet Packet Energy* [31].

Feature selection [26], meanwhile, consists in choosing, among an original set of features of size m , that subset of size n which best represents the original set in the sense of leading to the smallest classification error. The feature selection process can be conducted, among other methods, by means of

Exhaustive Search or *Sequential Forward/Backward Floating Search* [26]. On the one hand, *Exhaustive Search* explores all the possible subsets, i.e. 2^m if n is a free parameter, or $\binom{m}{n}$ if n is a preset constant. Therefore, this method guarantees the selection of the best subset but it is extremely computationally consuming. On the other hand, *Sequential Forward/Backward Floating Search* restricts the search to a smaller subtree allowing just the deletion and addition of some features at each step. Consequently, this method poses a more affordable computational load but does not guarantee the optimal subset selection, even though it has been proven to yield suboptimal results very close to optimality.

The improvement in the performance, offered by feature extraction and selection techniques, comes from (i) dimension reduction, which reduces the risk of over-fitting as long as it mitigates the curse of dimensionality problem [26, 39], and (ii) simplification of the resulting classifier, which results in using less memory and computational resources [26].

2.4. Support Vector Machines for classification

Support Vector Machines (SVM) is a statistical supervised machine learning technique, used both for classification and regression purposes. It was originally proposed in 1995 by Vapnik and Cortes [19, 40]. Although its principles and derivation differ from those of *Artificial Neural Networks* (ANN), some authors sometimes consider SVM as a special kind of ANN [41]. However, many authors refuse to do so due to essential differences between SVM and ANN techniques [42]. While SVMs mechanisms are mainly based on a rigorous geometrical and statistical approach, ANNs try to emulate the behavior of human brain neural system.

The original proposal of SVM aimed both the binary classification problem, just considering two possible classification classes, and the multiclass classification problem, which considers more than two classification classes.

Binary linear SVM classification performs the calculation of the optimal hyperplane decision boundary, separating one class from the other, on the basis of a training dataset. Optimality can be understood, depending on whether perfect classification of the training dataset is feasible and desired, in two senses:


- If perfect separability of training dataset classes can be achieved, a Hard Margin optimality can be used. In this case, the hyperplane decision boundary is chosen in order to maximize the distance from the hyperplane to the nearest training data point.
- If perfect classification is not possible or desired, a Soft Margin optimality is used. In this case, the hyperplane selection is a customizable tradeoff between minimizing the misclassification rate and maximizing the distance to the nearest properly classified training point.

The decision boundary hyperplane in SVM classification is calculated employing the training dataset. This decision boundary is completely determined by the so-called Support Vectors, a subset of training input vectors which by themselves alone lead to the same decision boundary. After this hyperplane is determined, the SVM classifier is ready to be used with a different dataset from the one used in the training stage. The assigned class, labeled either by +1 or -1, is decided depending on which side of the decision boundary the input vector falls. Figure 1 represents a graphical example of

linear SVM-based classification, both in the case of linearly separable classes and non-linearly separable classes.

SVM multiclass classification, meanwhile, usually tackles the classification and computation of the decision boundary by reducing the problem to a set of binary classification problems. The main such approaches are *pairwise* and *one-versus-all* classification methods [43]. Compact multiclass reformulations of the binary classification problem have been proposed too [43].

Figure 1. Representation of a *Support Vector Machine* classifier corresponding to a (a) linearly separable pattern, where the hyperplane is able to perfectly isolate green circles from red squares, and (b) non-linearly separable pattern, for which no hyperplane is able to separate all green circles from red squares.



The most general SVM linear binary classification problem, being mathematically rigorous, is stated as follows:

“Given a training dataset, $\{\mathbf{x}_i, d_i\}_{i=1}^N$, the goal is to compute the optimal weight vector \mathbf{w} , bias b , and slack variables ξ , such that satisfy the following restrictions:

$$d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \forall i = 1, 2, \dots, N$$

$$\xi_i \geq 0, \forall i = 1, 2, \dots, N$$

and such that the following cost function is minimized:


$$\Phi(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N \xi_i$$

where $\mathbf{x}_i \in \mathbb{R}^{m_0}$ denotes the i -th input vector, $d_i \in \{-1, 1\}$ denotes the class corresponding to the i -th input vector, $\xi = \{\xi_i\}_{i=1}^N$ are the slack variables, and the constant C is a user-specified parameter which determines the tradeoff between misclassification and maximum inter-class margin.”

In practice, most of the classification problems cannot be accomplished using a simple hyperplane as decision boundary. In such cases a more complex and elaborate decision boundary is required. SVM achieves this goal by increasing the dimensionality of the input space, of dimension m_0 , by applying a nonlinear transformation, denoted by $\varphi(\cdot)$, into a feature space of dimension $m_f > m_0$ (Figure 2). This transformation, $\varphi(\cdot)$, is performed with the hope of being able to reduce the misclassification probability in the transformed feature space. Most typical such transformation functions, as in the case

of ANN, are *radial basis functions*, *higher-order polynomials*, and *sigmoids*. Figure 2 represents a graphical example of SVM nonlinear classification.

Figure 2. Representation of a *Support Vector Machine* classifier with a nonlinear kernel. Function $\varphi(\cdot)$ is the nonlinear transformation mapping vectors from (a) the input space to (b) the feature space.



The boundary in the nonlinear classification problem is still an hyperplane, not in the original input space but in the feature space, and can be expressed as the points $\varphi(\mathbf{x})$ that satisfy that:

$$\mathbf{w}^T \varphi(\mathbf{x}) + b = 0 \quad (5)$$

where $\mathbf{x} \in \mathbb{R}^{m_o}$ and $\varphi(\mathbf{x}) \in \mathbb{R}^{m_f}$.

It has been shown, after the Lagrange multipliers method application, that the optimal weight vector can be expressed as [41]:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \varphi(\mathbf{x}_i) \quad (6)$$

where α_i stands for the Lagrange multiplier coefficients.

This way, the optimal decision boundary can be rewritten as:

$$\sum_{i=1}^N \alpha_i d_i \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}) + b = 0 \quad (7)$$

Renaming $u_i = \alpha_i d_i$ and $K(\mathbf{x}_i, \mathbf{x}) = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}) = \varphi(\mathbf{x})^T \varphi(\mathbf{x}_i) = K(\mathbf{x}, \mathbf{x}_i)$, the decision function, y , can be expressed as:


$$y = \sum_{i=1}^N u_i K(\mathbf{x}, \mathbf{x}_i) \quad (8)$$

In case of linear classifiers, $K(\mathbf{x}, \mathbf{x}_i)$ is the conventional Euclidean inner product of the input with the Support Vector \mathbf{x}_i . In case of nonlinear classifiers, $K(\mathbf{x}, \mathbf{x}_i)$ is the conventional Euclidean inner product of the nonlinear transformation $\varphi(\mathbf{x})$ of the input vector \mathbf{x} with the nonlinear transformation $\varphi(\mathbf{x}_i)$ of the Support Vector \mathbf{x}_i .

The decision function in Eq. (4) results in the architecture depicted in Figure 3, once the proper weights and Support Vectors have been computed in the training stage. Since only the Support Vectors contribute with non-zero α_i coefficients [41], just only the Support Vectors must be considered.

Classification, then, is performed by looking the sign of the output value, y , in Eq. (4). If $\text{sign}(y) = +1$, then this input is labeled as class +1. Otherwise it is labeled as class -1.

Figure 3. Architecture of a *Support Vector Machine* classifier. Inner product kernels, $K(\cdot, \cdot)$, denote the m_0 -dimensional kernel inner product of the input vector with each of the N_s Support Vectors.



The most well-known and widely used nonlinear kernels are *radial basis functions (RBF)*, *sigmoids*, and *polynomials*. The *RBF kernel* can be expressed as $K(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|^2)$, where γ is user-defined parameter, the *sigmoidal kernel* can be expressed as $K(\mathbf{x}, \mathbf{y}) = \tanh(\gamma \mathbf{x}^T \mathbf{y} + c_0)$, where $\gamma > 0$ and $c_0 < 0$ are user-defined parameters, and the *d-order polynomial kernel* can be expressed as $K(\mathbf{x}, \mathbf{y}) = (\gamma \mathbf{x}^T \mathbf{y} + c_0)^d$, where γ and c_0 are user-defined parameters and d denotes the polynomial degree. Beyond them, other kernels do also exist.

The underlying SVM training process undertakes the problem of minimizing a quadratic functional subject to linear constraints. This problem, known as *Quadratic Programming*, has a closed solution. Although the solution can be computed analytically making use of the Lagrange multipliers method, other computational methods are typically used, especially when the dimensionality of the problem becomes high. Some of these methods include, among others, *Interior Point* methods [44], the *Sequential Minimal Optimization (SMO)* algorithm [45, 46], *Incremental* methods [47], and the *Kernel-Adatron (KA)* algorithm [48]. More information about the SVM training process is gathered by Campbell and Ying [49].

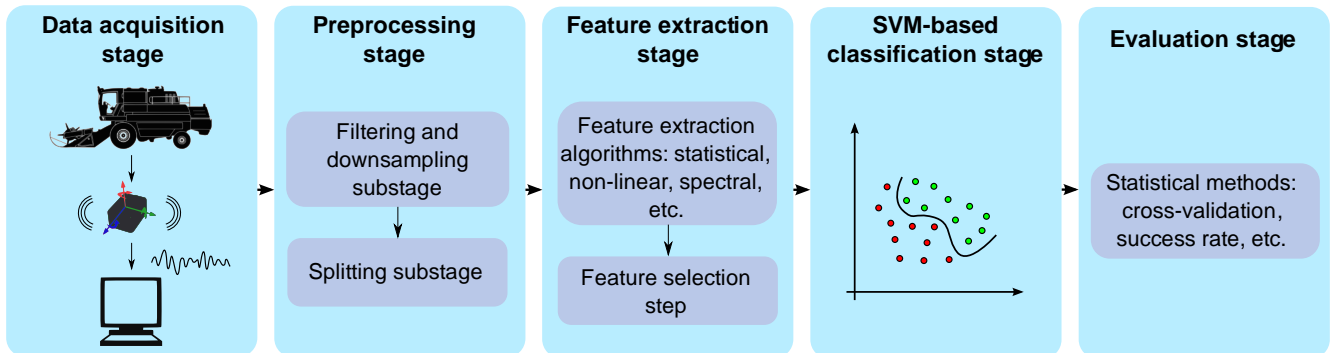
Those readers eager to discover the rigorous mathematical statement and solution of the problem underlying *Support Vector Machines* are encouraged to read the comprehensive SVM introduction provided by Haykin [41] or the tougher and more complete book by Steinwart and Christmann [50].

3. Materials and methods

The main processing stages undertaken along this article can be conceptualized as follows: (i) the data acquisition stage (Section 3.1), (ii) the preprocessing stage (Section 3.2), (iii) the feature extraction and selection stage (Section 3.3), (iv) the SVM-based classification stage (Section 3.4), and

(v) the evaluation stage (Section 3.5). In order to depict a high-level description of the methods, Figure 4 synthesizes the main substages comprised, which are explained more in depth along the rest of this section.


Figure 4. Overall block diagram summarizing the main processing stages in this work.



3.1. Data acquisition stage

Vibration data were experimentally obtained from an eleven-year-old New Holland TC56 harvester with 3800 working hours. Vibration signals were acquired with the harvester operating in threshing mode while its wheels were stopped. A Kistler 8690C50 triaxial accelerometer was used to measure the vibration signals in transverse, longitudinal and vertical axis (Figure 5). After several trial and error tests, the accelerometer sensor was located in the left side of the chassis of the harvester, placed neither too close nor too far from the analyzed rotating components. The sensor was placed using adhesive mounting method following the guidelines from Scheffer *et al.* [4]. The adhesive mounting method was selected since the frequency analysis in this article was bandlimited below 200 Hz and this method allows an accurate measure in this frequency range [4]. Vibration signals were acquired using the *NI Sound and Vibration Assistant* software and a *National Instruments (NI) data acquisition (DAQ) system*. The data acquisition system is composed by a *NI 9234 data acquisition module for analog input signals* and a *NI compact DAQ chassis NI cDAQ-9172* to connect the DAQ module with a laptop.

Figure 5. (a) Harvester schematic in which the red symbol represents the point of the chassis where the accelerometer sensor was located, the yellow cross represents the location of the engine, the blue cross represents the location of the threshing cylinder, and the orange cross represents the location of the straw chopper. (b) Coordinate axes of the accelerometer in this study: x axis is transverse to the harvester advance direction, y axis points to the harvester advance opposite direction, and z axis is vertical with respect to the ground. (c) Experimental setup for the data acquisition and zoom in on the location of the Kistler 8690C50 triaxial accelerometer.




A total of 18 different data acquisition processes were performed, in order to acquire data in all the combinations of the following harvester working conditions: (i) the engine speed status (*high speed/low speed*); (ii) the threshing operating status (*on/off*); (iii) the threshing balance status (*balanced/unbalanced*) while it was in the *on* operating status; (iv) the straw chopper operating status (*on/off*); and (v) the straw chopper balance status (*balanced/unbalanced*) while it was in the *on* operating status. The straw chopper was unbalanced by breaking a blade from it. The unbalance was performed this way because the breakage of a blade is a frequent unbalance source caused when the blade hits stones. Meanwhile, the threshing was unbalanced by adding an eccentric weight to the threshing cylinder. The unbalance was made in this manner because the threshing cylinder can typically get unbalanced when its bars suffer from a nonuniform wearing due to usage and an eccentric weight almost produces the same effect.

For each of the 18 acquisition processes, epochs or frames of about sixty seconds of machine operation were recorded using a sampling frequency of 1706.48 Hz, obtaining a total of 99120 samples per each sixty seconds long epoch.

3.2. Preprocessing stage

The acquired acceleration time-series data were first preprocessed in order to adapt them to the later feature extraction stage. The entire preprocessing stage was divided into the following three sub-stages (Figure 6): (i) a low-pass filtering sub-stage, (ii) a downsampling sub-stage, and (iii) a splitting sub-stage.

Figure 6. Block diagram representing the three preprocessing sub-stages.

In the first sub-stage, low-pass filtering took place. A digital IIR elliptic low-pass filter, with a cutoff frequency of 200 Hz, was applied to the input signal. The vibration frequencies of interest, which are the main harmonics of the rotating speeds, are located within the range from 0 to 200 Hz. This filtering was performed in order to remove noise and unwanted interferences to achieve a better performance.

Next, after filtering, the downsampling sub-stage took place. The input signal was decimated in order to reduce the sampling frequency by a factor of N_{fs} , where $N_{fs} \in \mathbb{N}$ is the decimation ratio. In this article a value of $N_{fs} = 4$ was chosen, taking into account the frequency range of interest. Therefore, the effective sampling frequency was reduced from the originally employed in the acquisition stage, 1706.5 Hz, to 426.625 Hz after downsampling.

Finally, the splitting sub-stage was conducted. The downsampled signal, coming from the second sub-stage, was then split into six epochs of about ten seconds, which was the frame size considered enough for keeping meaningful information of the vibration signal for the posterior feature extraction steps and for having a good frequency resolution in the subsequent FFT analysis. That way, a total of 4130 samples were obtained per each ten seconds long epoch.

All this preprocessing tasks were performed under *MATLAB*[®] programming environment.

3.3. Feature extraction and selection stage

This stage undertakes the dimensionality reduction of the input data-series coming from the previous stage. It is divided into feature extraction and feature selection sub-stages.

Firstly, the preprocessed data coming from the previous stage were brought in the feature extraction sub-stage, in order to achieve a simpler classifier. Assuming that the input signal to this stage is denoted as $x[n]$, where $n = 1, 2, \dots, N = 4130$, the following features were extracted:

- 1) **Average Power (P)**, defined as $\bar{P} = \frac{1}{N} \sum_{n=1}^N x[n]^2$. This feature quantifies the overall intensity of vibrations.
- 2) **Sample Entropy ($SampEn$)**, computed using the definition provided by Richman *et al.* [36]. This feature is a measurement of the signal regularity which assigns higher values to more random data, for instance when multiple vibration sources are superposed.
- 3) **Spectral Entropy ($SpecEn$)**, computed in the same way as by Hornero *et al.* [30]. This feature was employed because of its capability to quantify the flatness of the spectrum. The more frequency peaks the signal has, the greater this feature becomes.
- 4) **Mean Value (\bar{x})**, calculated as $\bar{x} = \frac{1}{N} \sum_{n=1}^N x[n]$. It reflects the amplitude of the background low frequency vibrations.

5) **Median frequency (MF)**, computed as the frequency which divides the power spectrum in two halves containing each the same energy. It was calculated in the same way as by Hornero *et al.* [30].

6) **Standard Deviation (σ)**, calculated, making use of the mean value \bar{x} previously defined, as the square root of the unbiased estimator of the variance, i.e. $\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x[n] - \bar{x})^2}$. This feature provides information about the width of the amplitude histogram distribution, giving additional information about the shape of the vibration signal.

7) **Skewness (s_0)**, calculated as the unbiased estimator $s_0 = \frac{\sqrt{N(N-1)}}{N-2} \frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^3}{\left(\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2\right)^{3/2}}$.

Skewness, being a measure of the asymmetry of the histogram distribution about its mean, can reflect vibration asymmetries due to mechanical faults.

8) **Kurtosis (k_0)**, calculated as the unbiased estimator $k_0 = \frac{N-1}{(N-2)(N-3)} ((N+1)k_1 - 3(N-1)) + 3$, where $k_1 = \frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^4}{\left(\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2\right)^2}$. This feature reflects the peakedness of the

histogram, giving information about the distribution of the vibration amplitude.

9) **Central Tendency Measurement (CTM)**. In the first place, the first-order differences scatter plot is constructed, representing $x[n+1] - x[n]$ in the X axis against $x[n+2] - x[n+1]$ in the Y axis. The proportion of points lying inside a circle of certain fixed radius is then returned as a measurement of the signal regularity. A radius of 0.05 g was selected in this article, due to its capability for separating the related classification classes. This feature offers a measurement of the randomness of the vibration signal, where a low value of this feature implies sharp changes in the vibration signal. Sharp changes in vibration signals may be caused both by high frequency vibrations or sudden transitions due to mechanical faults.

10) **Correlation coefficient (r) from the first-order differences scatter plot**. Likewise the previous feature, the first-order differences scatter plot is constructed first, obtaining both $X[n]$ and $Y[n]$ vectors. Then the Pearson's linear correlation coefficient between both vectors is computed as: $r = \frac{\sum_{n=1}^{N-2} (X[n] - \bar{X})(Y[n] - \bar{Y})}{\sqrt{\sum_{n=1}^{N-2} (X[n] - \bar{X})^2} \sqrt{\sum_{n=1}^{N-2} (Y[n] - \bar{Y})^2}}$, where \bar{X} and \bar{Y} are the mean

values of $X[n]$ and $Y[n]$, respectively. This feature offers a measurement of the unpredictability of the signal from the previous data, being more predictable the higher the $|r|$ is.

11) **Lempel-Ziv Complexity (LZC)**, computed as by Hornero *et al.* [30]. This feature offers a notion of complexity in a statistical sense. It characterizes the average information quantity within a signal and thus can reflect the superposition of several vibration sources.

12) **Crest Factor (C)**, calculated as $C = \frac{\max_n |x[n]|}{\sqrt{\frac{1}{N} \sum_i x[n]^2}}$, where N is the number of samples of the

time-series $x[n]$. This feature reflects the spikiness of the signal with respect to its RMS value and, therefore, it is useful to assess the presence of mechanical faults.

All of the above algorithms were selected on the basis of preceding books and articles on the vibration analysis literature [18, 51-53] as well as extrapolating ideas of studies from other fields [30, 34, 36].

Secondly, after having extracted these features from the preprocessed data-series, the feature selection sub-stage took place selecting the most suitable features among them. The feature selection process was undertaken by using the *Exhaustive Search* method, thus exploring all the possible subsets of features. With each of the explored subsets, linear SVM *leave-one-out* cross-validation was performed in order to assess the goodness of this subset. The feature subset with highest cross-validation accuracy was selected. The value of parameter C , involved in the SVM classification problem, was prefixed at 1 in all cases. Cross-validation accuracy was calculated for each classifier undertaking each of the five classification problems corresponding to the five contemplated rotating component states of the agricultural harvester: (1) the engine speed status (*high speed/low speed*), (2) the threshing operating status (*on/off*), (3) the threshing balance status (*balanced/unbalanced*), (4) the straw chopper operating status (*on/off*), and (5) the straw chopper balance status (*balanced/unbalanced*).

The choice of the *Exhaustive Search* method was possible due to the relatively small number of features involved, just twelve as noted above. If more features were to be explored it would be advisable to use *Sequential Forward/Backward Floating Search* for computational efficiency [26].

All the tasks of this stage were performed under *MATLAB*[®] programming environment using *LIBSVM* library [54, 55].

3.4. SVM-based classification stage

The classification stage took place once the previous processing stages had been performed. Among the huge variety of classifiers available, SVM classification was used in this article due to its nice properties: (i) great ability of generalization, (ii) low overtraining risk due to small datasets, and (iii) low computational load.

A different SVM-based classifier was employed for each of the five related classification problems, corresponding to the following five rotating component states of the agricultural harvester: (1) the engine speed status (*high speed/low speed*), (2) the threshing operating status (*on/off*), (3) the threshing balance status (*balanced/unbalanced*), (4) the straw chopper operating status (*on/off*), and (5) the straw chopper balance status (*balanced/unbalanced*). Each classifier received as input the subset of features that led to a maximum cross-validation accuracy (Subsection 3.3). If more than one such subset led to the maximum value, just one of them was chosen for the sake of simplicity. Each classifier provided as output one of the two classes associated with the input feature vector.

For each of the five classifiers, the *linear* kernel and the *radial basis function* (RBF), *sigmoidal*, and *third-order polynomial* nonlinear kernels were employed, providing a comparison between their accuracy. These SVM kernels were chosen because they are the most typical and widely used. The parameter C , involved in the SVM classification formulation, as well as the parameters γ and c_0 , involved in the kernel, were optimized by conducting an exponentially grid-search on these parameters [56]. The parameters that led to the highest cross-validation accuracy were selected.

LIBSVM toolbox [54, 55], running under *MATLAB*[®] programming environment, was once again employed for classification tasks.

3.5. Classifier performance evaluation stage

The *leave-one-out* cross-validation accuracy (Subsection 2.2), for each of the five individual classification problems under consideration, was computed in order to assess the goodness of the proposed classifying system. These five cross-validation accuracies, as well as the overall mean cross-validation accuracy, were used as a measurement of the accuracy of the SVM-based estimation method of each of the five aforementioned harvester states.

4. Results

The experimental results of the feature selection and classifier performance evaluation stages are presented in this section.

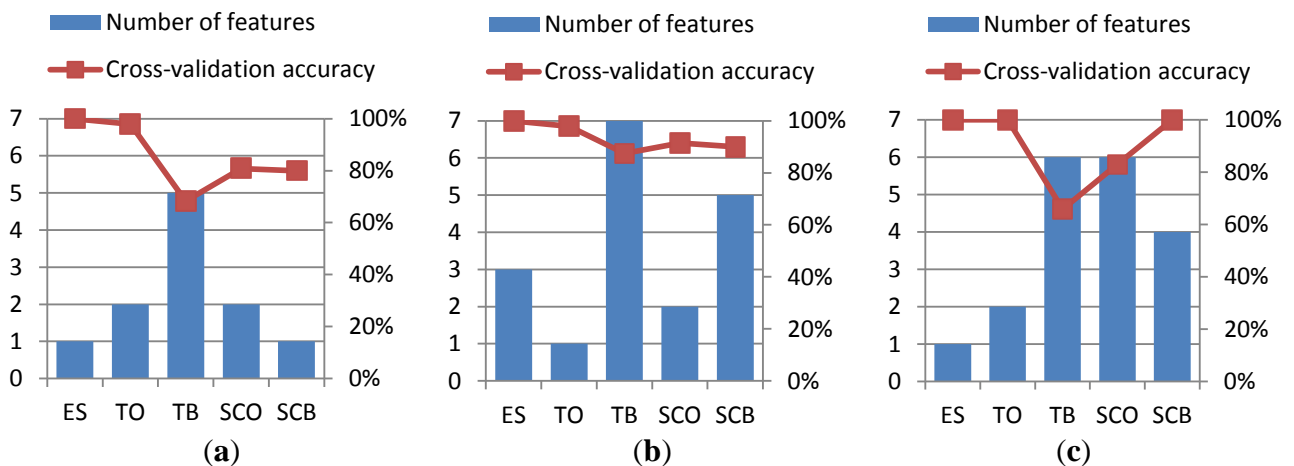
4.1. Feature selection

The selection of the best features, following the methods explained in Subsection 3.3, led to the best cross-validation accuracies and best particular chosen features shown in Table 1. It can be appreciated that, in all of the cases, the required number of features is lower than or equal to seven and that the achieved mean cross-validation accuracy is above 85%, for all the three axes of the accelerometer. The best cross-validation accuracies and the number of features needed to achieve them are depicted in Table 1.

Table 1. Feature selection results for each of the three axes acquired by the triaxial accelerometer. The number of features row shows the optimal number required to achieve the best cross-validation accuracy. The best feature subset row shows all the concrete feature subsets giving the highest cross-validation accuracy as a list of numbers whose legend corresponds to the list provided in Subsection 3.3. Highlighted in bold is the subset employed for the subsequent classifier performance evaluation stage. Each column corresponds to each considered rotating component classification problem.

		Classification problem				
		<i>Engine speed</i>	<i>Threshing operating</i>	<i>Threshing balance</i>	<i>Straw chopper operating</i>	<i>Straw chopper balance</i>
Transverse X axis of the accelerometer	Number of features	1	2	5	2	1
	Best features subset(s)	{9}	{10,11}	{4,6,7,9,11}	{2,8};{2,5}	5
	Cross-validation accuracy	100 %	97.87 %	68.29 %	80.85 %	80 %
	Mean CVA	85.40 %				
Longitudinal Y axis of the accelerometer	Number of features	3	1	7	2	5
	Best features subset(s)	{6,7,10}; {5,7,9}; {5,6,10}; {1,6, 10}	{5}	{1,2,7,8,9, 11,12}; {1,2, 4,7,8,11,12}; {1,2,4,6,7, 11,12}; {1,2,3,5,7,8,11}	{4,11}	{1,3,5,7,12}
	Cross-validation accuracy	100 %	97.87 %	87.49 %	91.49 %	90 %
	Mean CVA	93.37 %				
Vertical Z axis of the accelerometer	Number of features	1	2	6	6	4
	Best features subset(s)	{9}	{2,11};{2,3}	{2,3,5,6,8, 11}	{1,4,5,7,8,10}	{1,2,7,10}
	Cross-validation accuracy	100 %	100 %	65.85 %	82.98 %	100 %
	Mean CVA	89.77 %				

Figure 7. Number of features and cross-validation accuracy for each considered working conditions –(*ES*) engine speed, (*TO*) threshing operating, (*TB*) threshing balance, (*SCO*) straw chopper operating, and (*SCB*) straw chopper balance– using the accelerometer channel corresponding to (a) the transverse X axis, (b) the longitudinal Y axis, and (c) the vertical Z axis.



4.2. SVM classifier performance evaluation

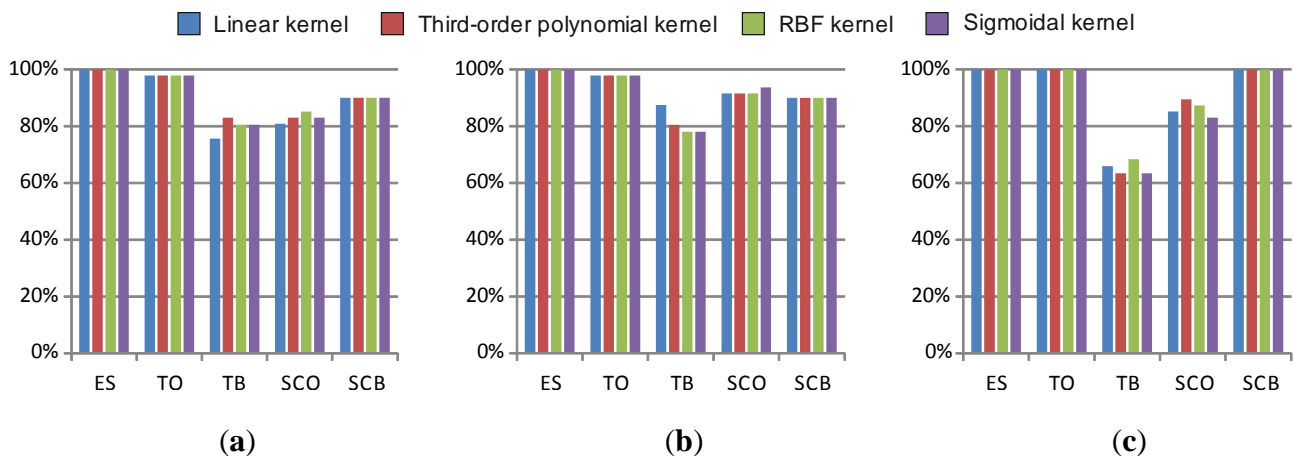
The results of the linear and nonlinear SVM classifier optimization, showing the best cross-validation accuracies and the related optimal parameters, are shown in Table 2. The previously selected features, highlighted in bold in Table 1, were used as input to the SVM classifier. It can be noticed that the contemplated nonlinear kernels do not outperform the linear kernel in most of the cases. Even in those cases that the accuracy is improved, only slightly differences are observed, never being higher than a 10%. Therefore, it seems accurate enough to use linear SVM classification for the tackled problem. A comparison between the different kernels cross-validation accuracy is also provided in Figure 8.

Table 2. Performance results for each of the three axes acquired by the triaxial accelerometer, comparing the different SVM kernels. The optimized parameters (C , γ , c_0) as well as the best cross-validation accuracy (CVA) are shown. Highlighted in bold is the best result for each classification problem.

		Classification problem					
		Engine speed	Threshing operating	Threshing balance	Straw chopper operating	Straw chopper balance	
Transverse X axis of the accelerometer	Linear kernel	CVA	100 %	97.87 %	75.61 %	80.85 %	90.00 %
		C	1	1	6	1	1.2
	Third order polynomial kernel	CVA	100 %	97.87 %	82.93 %	82.98 %	90.00 %
		C	0.03	32768	8192	2048	0.03
		γ	8	0.125	0.125	32	8
		c_0	0.03	0.03	0.5	0.5	0.03
	RBF kernel	CVA	100 %	97.87 %	80.49 %	85.10 %	90.00 %
		C	0.125	512	32	32	0.5
		γ	2	0.125	2	8	2
	Sigmoidal kernel	CVA	100 %	97.87 %	80.49 %	82.98 %	90.00 %
		C	2	2048	2048	8	2
		γ	0.5	0.125	0.125	8	2
c_0		0.03	0.03	0.03	0.5	0.03	
Longitudinal Y axis of the accelerometer	Linear kernel	CVA	100 %	97.87 %	87.49 %	91.49 %	90.00 %
		C	1	1	1	1	1
	Third order polynomial kernel	CVA	100 %	97.87 %	80.49 %	91.49 %	90.00 %
		C	8192	0.03	8192	0.03	2048
		γ	0.125	8	0.002	8	0.125
		c_0	0.03	0.03	8	0.03	0.03
	RBF kernel	CVA	100 %	97.87 %	78.05 %	91.49 %	90.00 %
		C	0.5	0.5	2	2	2
		γ	8	8	0.5	2	2
	Sigmoidal kernel	CVA	100 %	97.87 %	78.05 %	93.62 %	90.00 %
		C	2	32	512	8192	8
		γ	0.5	0.125	0.008	0.125	0.5
c_0		0.03	0.03	0.03	0.125	0.03	
Vertical Z axis of the accelerometer	Linear kernel	CVA	100 %	100 %	65.85 %	85.10 %	100 %
		C	1	1	1	430	1
	Third order polynomial kernel	CVA	100 %	100 %	63.41 %	89.36 %	100 %
		C	8192	512	2048	8192	0.03
		γ	0.125	0.5	0.125	0.03	8
		c_0	0.03	0.03	0.5	2	0.03
	RBF kernel	CVA	100 %	100 %	68.29 %	87.23 %	100 %
		C	0.125	32	2	8192	2

	Sigmoidal kernel	γ	2	0.5	32	0.03	0.5
		CVA	100 %	100 %	63.41 %	82.97 %	100 %
		C	2	128	512	32	8
		γ	0.5	0.125	0.5	0.125	0.5
		c_0	0.03	0.03	0.125	0.03	0.03

Figure 8. Cross-validation accuracy for each kernel under the considered working conditions –(*ES*) engine speed, (*TO*) threshing operating, (*TB*) threshing balance, (*SCO*) straw chopper operating, and (*SCB*) straw chopper balance– using the accelerometer channel corresponding to (a) the transverse X axis, (b) the longitudinal Y axis, and (c) the vertical Z axis.



5. Discussion

This article investigates about estimation of the status of multiple rotating components in agro-industrial machinery by processing vibration signals acquired from a single point of the machine structure. Three findings have been found.

The first finding of this article is that it is possible to accurately estimate the status of some rotating components in agro-industrial machinery by processing the vibration signal acquired from a single point of the machine structure. Moreover, the accelerometer sensor does not need to be placed very close to the analyzed rotating components, which makes the acquisition stage simple and non-intrusive. The previously presented results reveal the potential to estimate the status of distant components processing vibration signals from a unique sensor located in a fixed midway position of the harvester chassis (Figure 5), because a mean cross-validation accuracy higher than 85% was obtained. Previous work in the scientific literature has been made but only analyzing isolated mechanical components, using one accelerometer for each analyzed isolated component [13, 18, 53]. It is worth noting that, to the best of our knowledge, no previous articles have tackled the problem of estimating the status of multiple mechanical components from a unique vibration signal.

The second finding of this article is that the vibration signal can be acquired with an uniaxial accelerometer whose orientation does not significantly affect the accuracy of the classification. The comparison between the cross-validation accuracy results from the three axes of the accelerometer (Table 2) supports this conclusion. The higher differences in Table 2 are observed for the threshing balance status, for which differences around 20% can be noticed. However, almost no accuracy

differences were appreciated for the rest of the states, being lower than 10% in any other cases. Although vibrations are usually generated in a specific direction, the here obtained results suggest that the structure spreads them along all the axes making possible to use an arbitrary axis for detecting them.

The third finding of this article is that, when using a SVM classifier, a 85% mean cross-validation accuracy can be reached only requiring as input seven features at most, and no significant improvements are noticed from using nonlinear kernels with respect to using a linear kernel. Looking back to the results, a mean cross-validation accuracy greater than 85% was achieved irrespective of the selected accelerometer axis. Analyzing the individual cross-validation accuracy obtained for each rotating component, the suitability of the SVM classifier to estimate each separate status of the machinery is evident. On the one hand, the status of the rotating component with the best cross-validation accuracy was the engine speed, with a cross-validation accuracy of 100% in all cases (Table 2). On the other hand, the worst cross-validation accuracy was obtained by the threshing balance status, for which the cross-validation accuracy was between 63.41% and 87.49% (Table 2). Visually analyzing the vibration signal spectrum, there are differences when the engine speed is varied between high and low speed, while there are not visible changes in the signal spectrum when the threshing is balanced or unbalanced. These results show that the proposed SVM classifier is able to classify the status of rotating machinery with a high degree of accuracy when the difference between the spectrum signals is noticeable, such as the engine speed. They also show that it can obtain an acceptable cross-validation accuracy for rotating components when there is no visible difference between the spectrum signals, such as the threshing balance status. Comparing the fault detection accuracy against the results of Samanta *et al.* [53], who proposed a ANN-based classifier for the fault diagnostics of roller bearings based on the data obtained from several vibration signals extracting just five time-domain features, the present article has obtained poorer results. Nevertheless, these differences can be justified by taking into account that in Samanta's article five vibration signals from different locations of a unique component were processed and also because they were clean, as they came just from the isolated analyzed mechanical component. Meanwhile, in the present article just a unique accelerometer sensor is employed in order to detect five states of three different rotating components and, furthermore, the processed vibration signal contains the superposed signals coming from the three analyzed components as well as from other components of the machine. As it can be easily understood, the present article undertakes a much harder problem.

The major strength of the system proposed in this article is the simplicity of the data acquisition stage, employing just a unique sensor located in a single point for measuring the vibration signals. It is worth highlighting an article from Sugumaran *et al.* [18], who proposed a SVM-based classifier for the fault diagnostics of a unique roller bearing employing just one vibration signal. Our study, even though similar to Sugumaran's article, is wider in the sense of trying to assess several machinery rotating components at once instead of just one. Furthermore, the present article contemplates the detection of further machinery states, not just fault diagnostics.

Another strength of this article is that the proposed estimation method only needs, at most, seven features as input of the classifier, yielding to a simple SVM classifier with a low associated computational load. Moreover, the results showed no great differences with respect to the employed

SVM kernel. This fact highlights that a simpler linear SVM classifier is enough for achieving a good classification accuracy.

Nevertheless, there is a limitation of this work which should be taken into account before implementing the proposed estimation method. This limitation is related to the data acquisition process performed in this article to validate the proposed SVM-based system. The vibration signals were acquired with the harvester wheels stopped to facilitate the acquisition procedure. If the proposed estimation method were to be used when the monitored machine is in motion, low-frequency interference signals could appear. However, they are not expected to cause troubles because the frequencies of interest in the rotating components of these machines will almost surely be much higher than the interference frequencies.

The main application fields of the proposed SVM-based system are machinery monitoring and predictive maintenance. In relation to machinery monitoring, this system could be used for detecting the operating status of particular mechanical components, simplifying the wiring and reducing the number of sensors required. In relation to predictive maintenance, the results suggests that further advances of the present study may lead to fast and low cost machinery inspections, thus avoiding many mechanical faults and the nowadays expensive and time-consuming inspections.

A mixture of both conventional vibration signal analysis features, like frequency-domain [4, 6, 13, 18, 24, 31] and time-domain [51-53] based features, and other unconventional features, like nonlinear features [30, 34, 36], has been used in this article. The good classification accuracy levels achieved in this article, for example the obtained with the *Central Tendency Measurement* feature in estimating the engine speed status (Table 1), highlights the usefulness of these unconventional features while analyzing vibration signals in predictive maintenance. A future line is opened for further research employing other unconventional features in vibration analysis for predictive maintenance.

Furthermore, this article opens a new future line of research extending the here proposed system by using more than one accelerometer located in different points of the machine. It is expected that the processing of those signals all together could enable the estimation of an even higher number of states of the machine and could also improve the accuracy of the estimation.

6. Conclusions

The results obtained in this study give evidence that (i) it is possible to accurately estimate the status of some rotating components in agro-industrial machinery by processing the vibration signal acquired from a single point of the machine structure; (ii) the vibration signal can be acquired with an uniaxial accelerometer whose orientation does not significantly affect the accuracy of the classification; and (iii) when using a SVM classifier, a 85% mean cross-validation accuracy can be reached only requiring as input seven features at most, and no significant improvements are noticed from using nonlinear kernels with respect to using a linear kernel. Further advances of the present study may lead to a simplification of the wiring and a reduction in the number of sensors required in machinery monitoring, as well as to fast and low cost machinery inspections in predictive maintenance.

Acknowledgments

Ruben Ruiz-Gonzalez was financed during this article's research by a collaboration grant from the *Ministry of Education, Culture and Sport* of Spain (BOE-A-2013-7736).

Víctor Martínez-Martínez's work was made possible thanks to a *Formación de Personal Investigador* program grant, financed by the *Universidad de Valladolid* (Spain) and co-financed by *Banco Santander*.

Conflicts of Interest

The authors declare no conflict of interest.

References and Notes

1. Martin, K. F., A review by discussion of condition monitoring and fault diagnosis in machine tools. *Int. J. Mach. Tools Manuf.* **1994**, 34(4), 527-551.
2. Jardine, A. K. S.; Lin, D.; Banjevic, D., A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech. Syst. Signal Proc.* **2006**, 20(7), 1483-1510.
3. Girdhar, P.; Scheffer, C., 8 - Other predictive maintenance techniques. In *Practical Machinery Vibration Analysis and Predictive Maintenance*, Girdhar, P.; Scheffer, C., Eds. Newnes: Oxford, 2004; pp 221-234.
4. Scheffer, C.; Girdhar, P., *Practical Machinery Vibration Analysis and Predictive Maintenance*. Newnes: Oxford, 2004.
5. Wang, W. Q.; Ismail, F.; Farid Golnaraghi, M., Assessment of Gear Damage Monitoring Techniques Using Vibration Measurements. *Mech. Syst. Signal Proc.* **2001**, 15(5), 905-922.
6. Peng, Z. K.; Chu, F. L., Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mech. Syst. Signal Proc.* **2004**, 18(2), 199-221.
7. Li, Z.; Yan, X.; Tian, Z.; Yuan, C.; Peng, Z.; Li, L., Blind vibration component separation and nonlinear feature extraction applied to the nonstationary vibration signals for the gearbox multi-fault diagnosis. *Measurement* **2013**, 46(1), 259-271.
8. Albarbar, A.; Gu, F.; Ball, A. D., Diesel engine fuel injection monitoring using acoustic measurements and independent component analysis. *Measurement* **2010**, 43(10), 1376-1386.
9. Taghizadeh-Alisaraei, A.; Ghobadian, B.; Tavakoli-Hashjin, T.; Mohtasebi, S. S., Vibration analysis of a diesel engine using biodiesel and petrodiesel fuel blends. *Fuel* **2012**, 102, 414-422.
10. Vulli, S.; Dunne, J. F.; Potenza, R.; Richardson, D.; King, P., Time-frequency analysis of single-point engine-block vibration measurements for multiple excitation-event identification. *J. Sound Vibr.* **2009**, 321(3-5), 1129-1143.
11. Wang, X.; Makis, V.; Yang, M., A wavelet approach to fault diagnosis of a gearbox under varying load conditions. *J. Sound Vibr.* **2010**, 329(9), 1570-1585.
12. Bin, G. F.; Gao, J. J.; Li, X. J.; Dhillon, B. S., Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network. *Mech. Syst. Signal Proc.* **2012**, 27, 696-711.
13. Chen, F.; Tang, B.; Chen, R., A novel fault diagnosis model for gearbox based on wavelet support vector machine with immune genetic algorithm. *Measurement* **2013**, 46(1), 220-232.

14. McFadden, P. D.; Cook, J. G.; Forster, L. M., Decomposition of Gear Vibration Signals by the Generalised S Transform. *Mech. Syst. Signal Proc.* **1999**, 13(5), 691-707.
15. Wang, Y. S.; Ma, Q. H.; Zhu, Q.; Liu, X. T.; Zhao, L. H., An intelligent approach for engine fault diagnosis based on Hilbert–Huang transform and support vector machine. *Appl. Acoust.* **2014**, 75, 1-9.
16. Lei, Y.; Lin, J.; He, Z.; Zuo, M. J., A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mech. Syst. Signal Proc.* **2013**, 35(1–2), 108-126.
17. Cheng, G.; Cheng, Y.-l.; Shen, L.-h.; Qiu, J.-b.; Zhang, S., Gear fault identification based on Hilbert–Huang transform and SOM neural network. *Measurement* **2013**, 46(3), 1137-1146.
18. Li, Y.; Tse, P. W.; Yang, X.; Yang, J., EMD-based fault diagnosis for abnormal clearance between contacting components in a diesel engine. *Mech. Syst. Signal Proc.* **2010**, 24(1), 193-210.
19. Sugumaran, V.; Ramachandran, K. I., Effect of number of features on classification of roller bearing faults using SVM and PSVM. *Expert Syst. Appl.* **2011**, 38(4), 4088-4096.
20. Vapnik, V. N., *Statistical Learning Theory*. Wiley: New York, 1998; p 736.
21. Moguerza, J. M.; Muñoz, A., Support Vector Machines with Applications. *Stat. Sci.* **2006**, 21(3), 322-336.
22. Joachims, T., *Learning to Classify Text using Support Vector Machines: Methods, Theory and Algorithms*. Kluwer Academic Publishers: 2002; p 205.
23. Wu, C.-H.; Ho, J.-M.; Lee, D. T., Travel-time prediction with support vector regression. *IEEE Trans. Intell. Transp. Syst.* **2004**, 5(4), 276 - 281.
24. Su, H.; Shi, T.; Chen, F.; Huang, S., New method of fault diagnosis of rotating machinery based on distance of information entropy. *Frontiers of Mechanical Engineering* **2011**, 6(2), 249-253.
25. Dai, J.; Chen, C. L. P.; Xu, X.-Y.; Huang, Y.; Hu, P.; Hu, C.-P.; Wu, T., Machinery Vibration Signals Analysis and Monitoring for Fault Diagnosis and Process Control. In *Advanced Intelligent Computing Theories and Applications. With Aspects of Theoretical and Methodological Issues*, Huang, D.-S.; Wunsch, D., II; Levine, D.; Jo, K.-H., Eds. Springer Berlin Heidelberg: 2008; Vol. 5226, pp 696-703.
26. Widodo, A.; Yang, B.-S., Support vector machine in machine condition monitoring and fault diagnosis. *Mech. Syst. Signal Proc.* **2007**, 21(6), 2560-2574.
27. Jain, A. K.; Duin, R. P. W.; Mao, J., Statistical pattern recognition: a review. *IEEE Trans. Pattern Anal. Mach. Intell.* **2000**, 22(1), 4-37.
28. Kotsiantis, S. B., Supervised Machine Learning: A Review of Classification Techniques. *Informatika* **2007**, 31, 249-268.
29. Doğanaksoy, A.; Göloğlu, F., On Lempel-Ziv Complexity of Sequences. In *Sequences and Their Applications – SETA 2006*, Gong, G.; Hellesteth, T.; Song, H.-Y.; Yang, K., Eds. Springer Berlin Heidelberg: 2006; Vol. 4086, pp 180-189.
30. Vanluchene, A. L.; Vereecke, H.; Thas, O.; Mortier, E. P.; Shafer, S. L.; Struys, M. M., Spectral entropy as an electroencephalographic measure of anesthetic drug effect: a comparison with bispectral index and processed midlatency auditory evoked response. *Anesthesiology* **2004**, 1(101), 34-42.
31. Hornero, R.; Escudero, J.; Fernandez, A.; Poza, J.; Gomez, C., Spectral and Nonlinear Analyses of MEG Background Activity in Patients With Alzheimer's Disease. *IEEE Trans. Biomed. Eng.* **2008**, 55(6), 1658 - 1665.

32. GuoHua, G.; Yu, Z.; Guanghuang, D.; Yongzhong, Z., Intelligent Fault Identification Based On Wavelet Packet Energy Analysis and SVM. In *Control, Automation, Robotics and Vision, 2006. ICARCV '06. 9th International Conference on*, Singapore, 5-8 Dec. 2006 pp 1-5.
33. Grassberger, P.; Procaccia, I., Measuring the strangeness of strange attractors. *Physica D* **1983**, 9(1-2), 189-208.
34. Li, M.; Vitányi, P., *An Introduction to Kolmogorov Complexity and Its Applications*. 3rd ed.; 2008; p 792.
35. Aboy, M.; Hornero, R.; Abásolo, D.; Álvarez, D., Interpretation of the Lempel-Ziv complexity measure in the context of biomedical signal analysis. *IEEE Trans. Biomed. Eng.* **2006**, 53(11), 2282-2288.
36. Pincus, S. M., Approximate entropy as a measure of system complexity. *Proc. Natl. Acad. Sci. U. S. A.* **1991**, 88(6), 2297-2301.
37. Richman, J. S.; Moorman, J. R., Physiological time-series analysis using approximate entropy and sample entropy. *Am. J. Physiol.-Heart Circul. Physiol.* **2000**, 278(6), H2039-H2049.
38. Aggarwal, N.; Agrawal, R. K., First and Second Order Statistics Features for Classification of Magnetic Resonance Brain Images. *Journal of Signal and Information Processing* **2012**, 3(2), 146-153.
39. Zhou, B.-H.; Liu, P.; Liu, N. B.; Wu, X. H.; Lu, R.; Ni, X. M., Median frequency of surface EMG signal of antagonist muscles during repeated contractions. In *Engineering in Medicine and Biology Society, 1992 14th Annual International Conference of the IEEE Paris*, Oct. 29 1992-Nov. 1 1992 Vol. 4, pp 1626-1627.
40. Wang, X.; Paliwal, K. K., Feature Extraction and Dimensionality Reduction Algorithms and Their Applications in Vowel Recognition. *Pattern Recognit.* **2003**, 36, 2429-2439.
41. Cortes, C.; Vapnik, V., Support-vector networks. *Mach. Learn.* **1995**, 20(3), 273-297.
42. Haykin, S., *Neural Networks: A Comprehensive Foundation*. 2nd ed.; Prentice Hall PTR: New Jersey, USA, 1998; p 842.
43. Ren, J., ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. *Knowledge-Based Syst.* **2012**, 26, 144-153.
44. Hsu, C.-W.; Lin, C.-J., A comparison of methods for multiclass support vector machines. *IEEE Trans. Neural Netw.* **2002**, 13(2), 415-425.
45. Ferris, M. C.; Munson, T. S., Interior-point methods for massive support vector machines. *SIAM J. Optim.* **2006**, 13, 783-804.
46. Platt, J. C. *Sequential minimal optimization: A fast algorithm for training support vector machines*; Microsoft Research: Abril 1998.
47. Platt, J. C., Chapter 12: Fast training of support vector machines using sequential minimal optimization. In *Advances in Kernel Methods: Support Vector Learning*, 1st ed.; Schölkopf, B.; Burges, C. J. C.; Smola, A. J., Eds. MIT Press: Cambridge, 1998.
48. Shilton, A.; Palaniswami, M.; Ralph, D.; Tsoi, A. C., Incremental training of support vector machines. *IEEE Trans. Neural Netw.* **2005**, 16(1), 114-131.
49. Campbell, C.; Cristianini, N. *Simple learning algorithms for training support vector machines*; University of Bristol: 1998.
50. Campbell, C.; Ying, Y., *Learning with Support Vector Machines*. 1st ed.; Morgan & Claypool Publishers: San Rafael, CA, 2011.

51. Steinwart, I.; Christmann, A., *Support Vector Machines*. 1st ed.; Springer Publishing Company, Inc.: 2008.
52. Norton, M. P.; Karczub., D. G., *Fundamentals of Noise and Vibration Analysis for Engineers*. Cambridge University Press: 2003.
53. Tandon, N., A comparison of some vibration parameters for the condition monitoring of rolling element bearings. *Measurement* **1994**, 12(3), 285-289.
54. Samanta, B.; Al-Balushi, K. R., Artificial Neural Network based fault diagnostics of rolling element bearings using time-domain features. *Mech. Syst. Signal Proc.* **2003**, 17(2), 317-328.
55. Chang, C.-C.; Lin, C.-J., LIBSVM: A library for support vector machines. *ACM Trans. Intell. Syst. Technol.* **2011**, 2(3), 27:1-27:27.
56. Chang, C.-C.; Lin, C.-J. LIBSVM - A Library for Support Vector Machines. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm> (accessed on August 3, 2014)
57. Hsu, C.-W.; Chang, C.-C.; Lin, C.-J. *A Practical Guide to Support Vector Classification*; Department of Computer Science and Information Engineering, National Taiwan University: 2010.

© 2014 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/3.0/>).

ANEXO II: HISTORIAL INVESTIGADOR DEL AUTOR

El autor del presente Trabajo Fin de Máster, Rubén Ruiz González, ya desde antes de terminar la carrera de *Ingeniero de Telecomunicación* ha enfocado su trayectoria académico-profesional a la investigación científica. Tras disfrutar de una beca de colaboración de la Universidad de Valladolid, en el curso 2011-12, ha tenido claro su vocación investigadora, la cual se ha consagrado con su primera publicación científica en la revista *Sensors* aceptada el 4 de noviembre de 2013. En la nueva línea de investigación cubierta en este trabajo, otro artículo científico ha sido enviado para la consideración de su publicación (ver Anexo I).

Hasta la fecha, el autor de esta memoria cuenta con los siguientes méritos académicos e investigadores, incluyendo publicaciones científicas, becas y premios.

Premios y Menciones:

1. *Premio Extraordinario Fin de Carrera de Ing. de Telecomunicación (Promoción 2012-13).*
2. *Premio Finalista COIT-AEIT en Fundamentos y Tecnologías Básicas de la Información y las Comunicaciones, y sus Aplicaciones, por su Proyecto Fin de Carrera titulado Aplicación del filtro Kalman en la mejora de la precisión en el posicionamiento GPS aplicado a vehículos agrícolas.*

Becas de colaboración:

1. *Beca de colaboración en tareas de investigación en departamentos e institutos L.O.U. para alumnos de primer y de segundo ciclo de la Universidad de Valladolid (Curso 2011-12): “Fusión de datos de posicionamiento absoluto y relativo en un tractor agrícola para mejorar la precisión del guiado automático”.*
2. *Beca de colaboración del Ministerio de Educación, Cultura y Deporte para estudiantes en departamentos universitarios (Curso 2013-14): “Procesado mediante machine learning de las vibraciones mecánicas en vehículos agrícolas”.*

Artículos publicados en revistas científicas:

1. Gomez-Gil, J.; Ruiz-Gonzalez, R.; Alonso-Garcia, S.; Gomez-Gil, F.J. A Kalman Filter Implementation for Precision Improvement in Low-Cost GPS Positioning of Tractors. *Sensors* **2013**, *13*, 15307-15323.

Artículos publicados en revistas de divulgación científica:

1. Rubén Ruiz González; Jaime Gómez Gil; Francisco Javier Gómez Gil; Sergio Alonso García, Una implementación del filtro Kalman para la mejora de precisión en el posicionamiento de tractores basado en receptores GPS de bajo coste. *Revista MAPPING* **2014**, *23*(163), 16-28.