
CÁLCULO DE LA VIDA ÚTIL REMANENTE MEDIANTE TRAYECTORIAS MÓVILES ENTRE HIPERPLANOS DE MÁQUINAS DE SOPORTE VECTORIAL

DIEGO GALAR-PASCUAL,
LUIS BERGES-MURO, Ma. PILAR LAMBÁN-CASTILLO,
JOSÉ LUIS HUERTAS-TALÓN y BERNARDO TORMOS-MARTÍNEZ

RESUMEN

Se propone un nuevo método de predicción de vida útil remanente (RUL) inspirado en clasificadores de máquinas de soporte vectorial (SVM). Los datos históricos de condición de un sistema durante su tiempo de vida se utilizan para crear una clasificación mediante hiperplanos en SVM. Para estimar la RUL de un sistema, la velocidad de degradación se evalúa calculando la distancia mínima definida con base en las trayectorias de degradación; es decir, el acercamiento del sistema al hiperplano que segrega información de las condiciones buenas y malas en diferentes horizontes de tiempo. Se puede estimar la vida final de un componente específico, o la información de la RUL de una población ser calculada, mediante la agregación de múltiples estimaciones RUL usando un método de estimación de densidad. La degradación de un sistema se ve afectado por muchos factores desconocidos que, además de

complicar los comportamientos de degradación, dificultan la recolección de datos con calidad. Debido a falta de conocimiento y medidas incompletas, normalmente se carece de información importante del contexto de los datos recogidos. Por ello se agrupan datos históricos del sistema con gran variedad de patrones de degradación, con los que la búsqueda de un modelo global de predicción RUL es extremadamente difícil. Esto lleva a buscar técnicas avanzadas de predicción más allá de los modelos tradicionales. El modelo propuesto desarrolla un método eficaz de predicción RUL que aborda múltiples retos en pronósticos de sistemas complejos. Las similitudes entre trayectorias de degradación pueden contrastarse para enriquecer las metodologías actuales de prognosis. Para verificar el modelo se emplean datos del monitorizado de condición en rodamientos.

La detección de fallos, diagnósticos y pronósticos se realiza para elegir las diferentes acciones de gestión del mantenimiento y la programación de dichas acciones. Estos pasos se corresponden con la necesidad, en primer lugar, de percibir los fenómenos, de entenderlos, y finalmente, de actuar en consecuencia. Sin embargo, en lugar de entender un fenómeno que acaba de aparecer como un fracaso, resulta conveniente anticipar su manifestación y sus consecuencias con el fin de posteriormente y,

tan pronto como sea posible, recurrir a medidas de protección. Esto es lo que podría definirse como pronóstico y está fuertemente relacionado con la vida útil remanente (RUL, de remaining useful life) del activo observado.

El pronóstico revela ser una actividad de mantenimiento muy prometedor, ya que debería permitir mejorar la fiabilidad de todo el sistema. Además, los industriales muestran un creciente interés en esta temática que se convierte en un importante marco de investigación. Sin embargo,

teniendo en cuenta los beneficios que esta tecnología puede aportar a la seguridad, la economía y a los campos de gestión de recursos, la comunidad científica todavía no está de acuerdo en una definición formal, metodología o marco para instrumentar el proceso de pronóstico. Esto puede explicarse desde diferentes aspectos. En primer lugar, el pronóstico todavía no es un concepto estabilizado: no hay forma consensuada de entenderlo, lo que hace más difícil la definición de herramientas para el apoyo en aplicaciones reales. En segundo lugar, existen

PALABRAS CLAVE / Mantenimiento / RUL / SVM / Velocidad de Degradación /

Recibido: 19/01/2012. Modificado: 23/08/2013. Aceptado: 27/08/2013.

Diego Galar-Pascual. Ingeniero de Telecomunicación y Doctor Ingeniero, Universidad de Zaragoza (UniZar), España. Catedrático, Lulea University of Technology, Suecia. Dirección: Division of Operation and Maintenance Engineering, 97187 Lulea, Suecia. e-mail: diego.galar@ltu.se

Luis Berges-Muro. Doctor Ingeniero Industrial, UniZar, España. Profesor, UniZar, España. e-mail: bergesl@unizar.es

Ma. Pilar Lambán-Castillo. Doctora en Ingeniería Industrial y Postgraduada en Organización Industrial, UniZar, España. Profesora, UniZar, España. e-mail: plamban@unizar.es

José Luis Huertas-Talón. Doctor Ingeniero Industrial, UniZar, España. Profesor, UniZar e Instituto de Educación Secundaria Corona de Aragón, Zaragoza, España. e-mail: jhuertas@unizar.es

Bernardo Tormos-Martínez. Doctor Ingeniero Industrial, Universitat Politècnica de València (UPV), España. Profesor, UPV, España. e-mail: betormos@mot.upv.es

muchos métodos para la predicción cuya aplicación depende en gran medida de los conocimientos disponibles en el sistema monitorizado. En tercer lugar, la vaguedad de la definición del proceso de pronóstico impide señalar los desafíos que implica para los investigadores.

El propósito de este trabajo es analizar y discutir las ventajas de la información suministrada por máquinas de soporte vectorial (SVM, de support vector machines) en el diagnóstico para realizar pronósticos adecuados sobre la base de la misma. El objetivo general es mostrar una clara diferencia entre la información de los diagnósticos, realizados muchas veces por herramientas de detección anómalas, y la información de pronóstico, a la cual no se presta la atención adecuada para llevar a cabo y desarrollar los sistemas de pronóstico real.

El Concepto de Pronóstico

La norma europea sobre terminología de mantenimiento (EN 13306, 2001) no define 'pronóstico'. Esto revela que se trata de una nueva área de interés. El pronóstico se relaciona tradicionalmente con la mecánica y la fatiga. Se denomina pronóstico a la predicción de la vida útil de un sistema y corresponde al último nivel de la clasificación de los métodos de detección de daños presentados por Farrar y Lieven (2007). El pronóstico también puede ser definido como una medida de probabilidad: una forma de cuantificar la probabilidad de que una máquina funcione sin un error o fallo hasta algún momento futuro. Este valor pronóstico probabilístico es más que una indicación interesante de cómo el error o fallo puede tener consecuencias catastróficas, y de cómo el jefe de mantenimiento necesita saber si los intervalos de inspección son los adecuados.

Finalmente, el pronóstico puede ser definido como ha propuesto recientemente la Organización Internacional de Normalización (ISO 13381-1, 2004): el pronóstico es la estimación del tiempo hasta el fracaso y el riesgo para uno o más modos de fallo existentes y futuros. En esta acepción, también se le denomina pronóstico a la predicción de la vida útil de un sistema, ya que es un proceso cuyo objetivo es predecir la vida útil restante (RUL) antes de que se produzca un fallo, dada la condición actual de la máquina y el perfil de las operaciones pasadas (Jardine *et al.*, 2006). Estos enfoques se basan en la noción de fracaso, es decir, la finalización de la capacidad de realizar una función determinada, lo que implica que el pronóstico sea asociado con un grado de aceptación. Con todo lo ante-

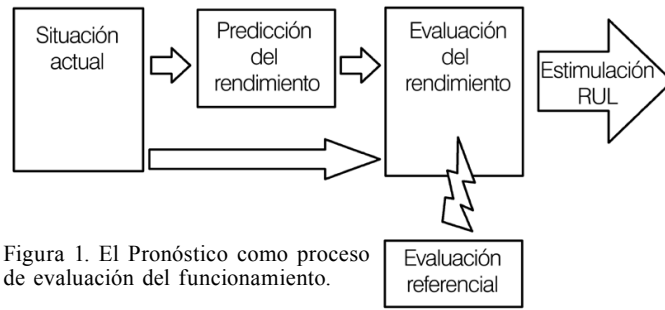


Figura 1. El Pronóstico como proceso de evaluación del funcionamiento.

rior, el pronóstico debe basarse en criterios de evaluación, cuyos límites dependen del sistema en sí mismo y de los objetivos de rendimiento (Dragomir *et al.*, 2007, 2008), y puede ser dividido en dos sub-actividades: una primera para predecir la evolución de una situación en un momento dado, y una segunda para evaluar la situación prevista en lo que respecta a la evaluación de referencia (Figura 1).

Un problema fundamental puede destacarse: la precisión de un sistema de pronóstico se relaciona con su capacidad para aproximar y predecir la degradación de los equipos; la fase de predicción es crítica. Una mirada a los indicadores de pronóstico permite señalarlo. El pronóstico es, en esencia, un proceso de elevada incertidumbre; es por ello necesario poder construir medidas para evaluar el rendimiento de los diferentes sistemas de prognosis. La principal medida pronóstica que se persigue es la predicción del tiempo hasta el fallo (TTF, de time to failure), también llamada vida útil remanente (RUL).

Inicialmente, el concepto de pronóstico ha sido definido brevemente y se sitúa dentro de las estrategias de mantenimiento. Por lo tanto, la siguiente sección está dedicada al análisis de las herramientas utilizadas en los diagnósticos y la información producida por ellas para predecir el RUL en una etapa posterior. Finalmente, el SVM se muestra como una herramienta útil para diagnóstico y una herramienta de pronósticos prometedora acorde a la metodología propuesta.

Extracción de las Características

La extracción de características (proceso conocido en el campo del condition monitoring como feature extraction) es el primer paso después de la adquisición masiva de datos para realizar diagnósticos y pronósticos posteriores que contribuyan a extraer información de los datos y de este modo conocer el estado del sistema mecánico analizado. Esto ayuda a maximizar la información útil a partir de los datos en bruto. La identificación de características relevantes conduce a diagnósticos precisos de defectos, más rápidos y fáciles. Las caracte-

rísticas seleccionadas deben ser sensibles a los fallos de la máquina y también ser resistentes al ruido de fondo. Otro aspecto importante a tener en cuenta en la selección de las características son los requisitos de cálculo asociados a su determinación. Se buscan características con menores requisitos de cálculo. Otra consideración importante en la selección de características es que la complejidad del cálculo de esas características

debería ser baja para permitir el monitorizado de la condición en tiempo real, pues si bien la capacidad de los microprocesadores es cada día mayor, algunas características implican algoritmos complejos. Las metodologías asociadas para extraer las características buscadas son la utilización de diversos métodos de procesamiento de señales como el dominio temporal, el dominio de frecuencia y el análisis tiempo-frecuencia. La extracción de características se basa en la construcción y selección de las mismas.

El diagnóstico de fallos existentes en un elemento rodante se centra principalmente en el dominio de frecuencia, por ejemplo, utilizando la transformada de Fourier, o en el dominio tiempo-frecuencia, utilizando la transformada wavelet. En las primeras etapas de desarrollo del fallo, el daño no es significativo y la señal defectuosa está enmascarada por el ruido presente en la señal adquirida. La periodicidad de la aparición de alguna amplitud en la señal no es significativa. Por lo tanto, el análisis espectral puede no ser eficaz.

Por otro lado, aunque la periodicidad sea significativa, también es recomendable utilizar la función dominio temporal, ya que las señales normales y defectuosas difieren en sus características estadísticas en dominio de tiempo. Por lo tanto el uso combinado de las características de dominio temporal con otros dominios pueden mejorar la exactitud del diagnóstico. Algunas de las características dominio temporal utilizadas en la literatura aparecen en la Tabla I.

Entre estas características, la curtosis es una característica usada en las máquinas con elementos rodantes. La curtosis define el apuntamiento de la amplitud en la señal. Las características de curtosis, factor de cresta y factor de impulso son magnitudes adimensionales. Estas características son independientes de la magnitud de la potencia de la señal. Los valores RMS (valor cuadrático medio o root mean square), valor de pico, desviación estándar y NNL (valor normal de probabilidad negativa o normal negative likelihood) son totalmente dependientes de la potencia de la señal. Algunos factores perjudiciales, como la calidad de los sensores o el lugar donde están monta-

dos pueden influir en la potencia y calidad de la señal adquirida. La principal ventaja de las características no dimensionales es que son inmunes a estos factores perjudiciales. Sin embargo, el RMS es una característica importante en el procesamiento de la señal. Mide la potencia de la señal y puede ser utilizado para normalizarla, por lo que algunas características se derivan del RMS.

Algunas características pueden no contribuir al diagnóstico de fallos e incluso degradar el rendimiento del diagnóstico. El índice de separación se utiliza para definir cuan diferente es la información aportada por las variables seleccionadas, y es obvio que cuan mayor el índice de separación mayor exactitud en el proceso de diagnóstico, ya que la información dada por cada parámetro es diferente y no redundante (Sreejith *et al.*, 2008).

Para dos señales que se presentan para ser comparadas, sean \bar{m}_d y \bar{m}_h , éstas representan la media de las muestras de cada señal respectivamente. S_d y S_h representan la desviación estándar. Un índice de separación (SI) se define como

$$SI = \frac{|\bar{m}_d - \bar{m}_h|}{S_d + S_h} \quad (1)$$

Para fines de predicción de la trayectoria es importante, para seleccionar correctamente las características que éstas exhiban, algunas de las tendencias previsible que se relacionan con la salud del sistema. Esta característica sigue una tendencia ascendente en el tiempo, que sería útil en la predicción sin actualizaciones de medidas. La precisión de la predicción será muy susceptible a los cambios bruscos en la tendencia de la característica, ya que la predicción se basa sólo en el último estado con una actualización de la medida y un modelo de transición de estado. No hay ninguna posibilidad de que el modelo cambie sin actualizaciones de medidas, ya que el estado predicho estimará incorrectamente la trayectoria actual de las características.

Diagnos Utilizando el Clasificador SVM

Los clasificadores median- te máquinas de soporte vectorial están basados en hiperplanos que separan los datos de a clasificar en dos subgrupos que poseen cada uno una etiqueta propia. En medio de todos los posibles planos de separación entre las dos clases, existe un único hiperplano de separación óptimo, de forma que la distancia entre el hiperplano óptimo y el patrón de entrenamiento más cercano sea

TABLA I
CARACTERÍSTICAS EN
EL DOMINIO TIEMPO

Característica	Definición
Valor de pico	$Pv = (1/2)[\max(x_i) - \min(x_i)]$
RMS	$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2}$
Desviación estándar	$Std = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
Curtosis	$Kv = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{RMS^4}$
Factor de cresta	$Crf = Pv / RMS$
Factor holgura	$Clf = \frac{Pv}{(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i })^2}$
Factor impulso	$Imf = \frac{Pv}{\frac{1}{n} \sum_{i=1}^n x_i }$
Factor forma	$Shf = \frac{RMS}{\frac{1}{n} \sum_{i=1}^n x_i }$
Valor normal de robabilidad negativa (NNL)	$NNL = -\ln L; L = \prod_{i=1}^N f(x_i, u, \sigma)$

máxima. Este proceso de entrenamiento supervisado con datos previos que permiten clasificar el universo de muestras en dos grupos es el escenario más común. De hecho, SVM fue desarrollado inicialmente para clasificar dos clases de objetos.

La dificultad estriba fundamentalmente en la selección de una función de decisión para dicha clasificación binaria. Dicha función de decisión es una medida de la distancia en un espacio n-dimensional es lo que se conoce como 'kernel' o núcleo del SVM y definirá el rendimiento




Figura 2. Problema de Clasificación de tres clases.

del mismo. Sin embargo, hay muchas aplicaciones en las que el número de clases es más de dos, como el ejemplo ilustrado en la Figura 2. Para dar cabida a los problemas multiclase, una solución consiste en combinar varios SVM binarios juntos. El 'multiclase SVM uno-contra-todos' (Hsu y Lin, 2002) es uno de ellos.

Supongamos que hay k clases de conjuntos de datos para ser separados. Dados l datos de entrenamiento $(X_1, y_1), \dots, (X_l, y_l)$, estos l datos son la entrada del SVM. La entrada del SVM en el caso de diagnosis es un vector de l características, por lo cual una vez extraídas las características de la señal adquirida, éstas son introducidas a la SVM. El $y_i \in \{1, 2, 3, \dots, k\}$ es la salida del SVM y es el indicador de la categoría (clase) a la que pertenece un conjunto de datos. El método 'uno contra todos' transforma los problemas multiclase en k subproblemas de clasificación binaria. Los i^{th} subproblemas de clasificación binaria generan etiquetas de la siguiente manera. Si el conjunto de datos pertenece a la i^{th} clase se etiqueta con un 1 y el resto de conjuntos de datos no pertenecientes a esa clase con -1. La fórmula para este i^{th} SVM binario es

$$\min \frac{1}{2} (\omega^i)^T \omega^i + C \sum_{j=1}^l \xi_j^i (\omega^i)^T$$

$$(\omega^i)^T \phi(x_j) + b^i \geq 1 - \xi_j^i, \text{ if } y_j = i \quad (2)$$

$$(\omega^i)^T \phi(x_j) + b^i \leq -1 + \xi_j^i, \text{ if } y_j \neq i$$

$$\xi_j^i \geq 0, j = 1, \dots, l$$

donde la función de decisión o distancia se establece en base a la mínima calculada la pertenencia a la clase correspondiente. Como cada SVM sub-binario tiene una función de decisión, pueden obtenerse k funciones de decisión para k-clases, lo que implica que diferentes funciones de distancia se pueden implementar simultáneamente de cara a evaluar diferentes subproblemas en la segregación de las diferentes k clases:

$$(\omega^1)^T \phi(x) + b^1 \text{ y } (\omega^k)^T \phi(x) + b^k \quad (3)$$

La clase asignada en la clasificación para cada conjunto de datos x es la clase con el mayor valor en la función de decisión, como se ilustra en la Figura 3. Esto es

$$i = \arg \max((\omega^i)^T \phi(x) + b^i) \quad (4)$$

lo que implica que en el uno contra uno, la clase habrá sido contrastada con cada uno de los grupos y el valor acumulado máximo pertenecerá al de la categoría más cercana o

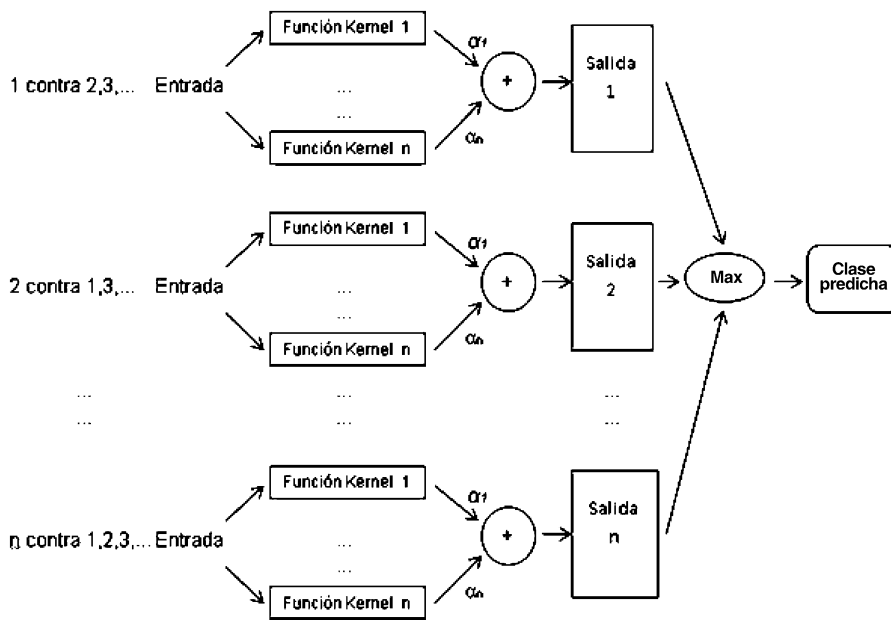


Figura 3. SVM multiclase.

de menos distancia acorde a la función acumulación descrita anteriormente. Sin embargo, es de recalcar la extraordinaria dependencia del rendimiento de este clasificador de la función decisión o distancia seleccionada, es decir el 'kernel' o núcleo. Por otro lado, la ventaja reside en que las máquinas SVM son clasificadores flexibles. Cuando la función kernel es no lineal, la función de decisión es también no lineal, por lo que el SVM proporciona la separación precisa de los puntos mediante una superficie no lineal en el espacio original de los patrones, así como la maximización de la distancia entre los planos de separación en un espacio dimensional más alto.

El resultado final es una clasificación exacta basada en el éxito de estas técnicas para conseguir la agrupación de los datos dados para una clase específica. Esta es la base de diagnóstico; es decir, la identificación del fallo existente, pero no proporciona ninguna información sobre la magnitud del daño presente. Ello implica la necesidad del pronóstico.

Estimación de la Trayectoria

Considerando un proceso de degradación que no implica un mantenimiento limitado, el proceso puede componerse de una secuencia de etapas irreversibles, ya sean discretas o continuas, desde las nuevas hasta las anteriores etapas, que pueden ser implícitamente expresadas por la trayectoria de los datos de condición medidos, o de las características. Por tanto, el RUL del sistema puede ser estimado si la tendencia de su degradación futura puede proyectarse a partir de los casos históricos que han fallado. Puede calcularse la similitud

entre las trayectorias de degradación de los diferentes casos, y entonces el tiempo de fallo de un determinado caso podrá estimarse en función del tiempo real de fallo de casos similares. Por último, los RUL estimados a partir de múltiples casos históricos pueden agregarse para generar la predicción final del RUL.

Trayectorias en el espacio de características

El seguimiento de la trayectoria implica la estimación y la predicción de uno o más parámetros de un sistema que utiliza las observaciones realizadas a través del tiempo. Estas observaciones son, por lo general, la medición de propiedades físicas tomadas de un sensor en particular, como la vibración para aplicaciones de monitoreo de condición (CM, de condition monitoring). Estas propiedades físicas pueden incluir la posición, velocidad y aceleración. Hay casos prácticos donde las mediciones no proporcionan información suficiente para realizar un diagnóstico adecuado ni un pronóstico. Puede ser más útil tomar las características de un sensor de datos en masa cuando proporciona una información más adecuada para su seguimiento.

El método de pronóstico propuesto implica el seguimiento de la trayectoria real de las mediciones de las características por sí mismas. Esto es útil cuando se sabe a priori que una determinada característica está ligada a un proceso o evento en particular. En este caso, la trayectoria de la característica puede ser indicativa de la situación actual de un proceso, y en la aplicación CBM (condition based maintenance), donde el objetivo es predecir cuándo un sistema mecá-

nico va a fallar teniendo como base el análisis de una característica. Si se advierte que una característica describe la actual 'salud' del sistema supervisado, la trayectoria de la característica puede ser rastreada para estimar la salud actual y predecir con anticipación si el sistema va a fracasar.

Ya que las características se derivan de las mediciones tomadas por un sensor en particular, son susceptibles a las incertidumbres relacionadas con la precisión del sensor. Estas incertidumbres son análogas a la medición de ruido de fondo en atributos físicos. Sin embargo, la medición del ruido asociado a un sensor en particular no se puede aplicar directamente a las características, ya que éstas no pueden estar linealmente relacionadas con los datos originales recopilados por el sensor.

Las trayectorias de características se rigen por un modelo dinámico que describe cómo cambian con el tiempo. Ya que las características se extraen de datos que obedecen a las leyes de la física, algunas de ellas tienen limitaciones que restringen su dinámica en el tiempo, tales como la posición, la velocidad y la aceleración. Las características que siguen una tendencia consistente y predecible son útiles para el seguimiento, mientras que las que tienen cambios bruscos e impredecibles pueden ser más útiles a efectos de clasificación. La Figura 4 muestra un ejemplo de cómo dos características diferentes se comportan en el tiempo.

La gráfica superior muestra los puntos de color blanco con un tamaño concreto de fallo en la pista interior. Al mismo tiempo los puntos negros son el conjunto de entrenamiento que corresponde a un tamaño más grande de fallo. La gráfica siguiente presenta una etapa posterior donde la nube de puntos se está moviendo hacia tamaños de fallo más grandes. Estos mapas de características de dos dimensiones utilizan el valor de cresta y el valor de curtosis en el proceso de fusión.

Tiempo para el fallo

El tiempo para el fallo (TTF, de time to failure) es la cantidad de tiempo que queda antes de que un sistema alcance un fallo mecánico. El fallo es un evento teórico que se produce cuando el valor de una propiedad traspasa un cierto umbral de fallo predeterminado. El TTF se calcula cada vez que el valor de la propiedad cruza un valor particular de interés llamado umbral de detección. La estimación del TTF se ajusta a cero antes de que el valor de haya cruzado el umbral de detección. Después de que el umbral de detección ha sido atravesado, el TTF se calcula mediante la propagación de la pista de característica actual hacia adelante en intervalos de tiempo




Figura 4. Dos etapas en la degradación de rodamientos.

basados en la metodología de análisis. La estimación del TTF es la diferencia entre el intervalo de tiempo actual y el tiempo de cruce del umbral previsto. Este proceso se muestra en la Figura 5.

La vida útil restante (RUL) es la cantidad de tiempo que queda antes de que un sistema deje de funcionar dentro de límites aceptables. El RUL se calcula de manera muy parecida al TTF, excepto que en lugar de un umbral de fallo, existe un umbral de funcionamiento que supone un límite superior. Como se muestra en la Figura 5, el umbral de funcionamiento del RUL es menor que el umbral de fallo, dando lugar a un valor inferior para el RUL que para el TTF. Esto tiene sentido, ya que es deseable reparar el sistema antes del fallo, sin dejar de utilizar parte de la vida útil antes del mantenimiento. Sin embargo el RUL es una aplicación dependiente de que las tolerancias especificadas queden perfectamente definidas para un sistema dado. Debido a esto, los resultados se dan para el TTF en lugar de para el RUL.

Calculo de trayectorias

Supongamos que M diferentes categorías de fallo han sido seleccionadas con éxito para reconocer los M distintos estados secuenciales de interés para un mecanismo de fallo. El número de cate-

gorías (M) correspondientes a diversos estados de degradación en un modo de fallo depende de los datos disponibles y de la experiencia previa de los mantenedores. Por ejemplo en el caso presentado se estudian tres fases de degradación acordes al tamaño del fallo ($0,007''$; $0,014''$ y $0,021''$) y que implican según este tamaño una fase inicial (donde el fallo es pequeño pero detectable), una fase intermedia (donde el fallo es considerable y supone una degradación inevitable) y una fase avanzada (donde el tamaño del fallo es grande y por tanto la degradación es rápida). Estas tres fases de degradación,

consecuencia de los datos y la experiencia de los expertos marcarán los límites de los hiperplanos en pro de una adecuada clasificación del elemento en una de las tres fases de deterioro previamente mencionadas.

La presentación de las secuencias de observación temporalmente ordenadas; esto

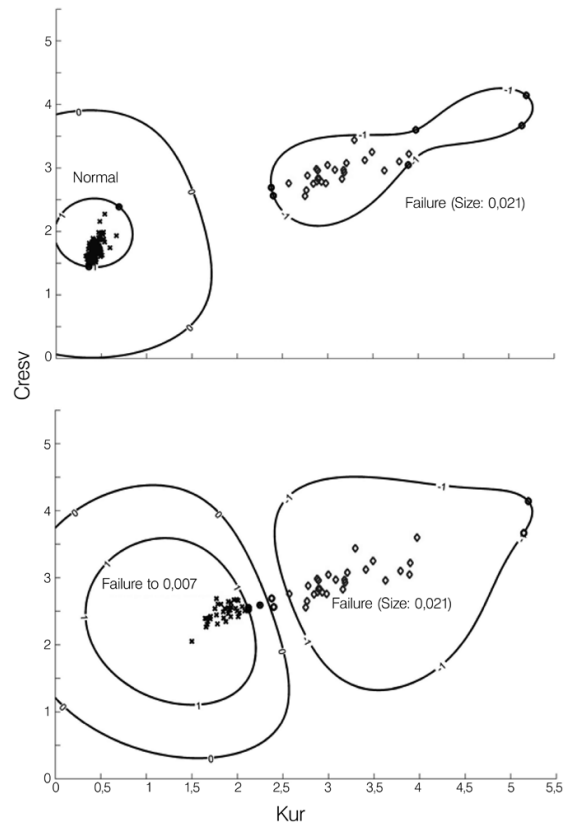


Figura 6. Evolución de la trayectoria con kernel gaussiano SVM.

es, la posición del elemento a diagnosticar según las características seleccionadas en función del tiempo, produciría el tipo de trayectorias que se muestra en la Figura 6. Estas trayectorias de los elementos en el espacio de características cruzaran diferentes áreas correspondientes a los estados conoci-




Figura 5. Diferencia entre RUL y TTF.

dos y seleccionados por el usuario. En este caso, se consideran tres estados conocidos: rodamientos normales (0,007" de tamaño de fallo), un tamaño de fallo medio en la pista interior (hasta 0,014") y un tamaño de fallo inaceptable que supone degradación inminente (0,021").

Si las coordenadas del estado medido están en uno de los M límites definidos para cualquier secuencia de observación, entonces, se podría decir que la máquina está en este estado.

Las coordenadas de los puntos de intersección de las trayectorias para los diferentes estados a lo largo de los ejes vida/uso de la Figura 6 representan la transición entre estados y por lo tanto los instantes temporales que interesa predecir para fines de prognosis. Son estos puntos de transición de estado los que nos permiten en base a los modos de fallo seleccionados, evaluar el tiempo de degradación entre ellos sin necesidad de conocer la física que subyace detrás de ellos de cara a realizar pronósticos y por tanto predecir el tiempo de degradación o deterioro.

El objetivo del proceso del diagnóstico consiste en reconocer los M estados distintos de fallo de una máquina o conjunto de elementos. En el caso de poblaciones de ítems elevadas, estos pueden usarse como datos de entrenamiento para la máquina SVM consiguiendo clasificaciones más exactas. El conjunto de datos para entrenar al sistema se presentará como una secuencia de observación temporalmente ordenada, como se ilustra en la Figura 6, similar a una nube de puntos en movimiento hacia los límites con diferentes períodos de transición (cada elemento usado para el entrenamiento o ulterior prognosis habrá tenido o tendrá una forma diferente de degradación). Supongamos que las secuencias de observación están disponibles desde varias unidades similares, recogidas con el fin de desarrollar modelos de diagnóstico y pronóstico. Esto dará como resultado vectores estimados de los períodos de transición de estado. Estos vectores de proporcionan la información necesaria para llevar a cabo pronósticos. Es decir, con poblaciones amplias de elementos similares trabajando en idénticas condiciones se podrán establecer distribuciones estadísticas para modelos RUL aplicables al total de la población con cierto intervalo de confianza

El procedimiento es el siguiente. Se parte del supuesto de que estos períodos siguen una distribución multivariante. Una vez la distribución ha sido eva-

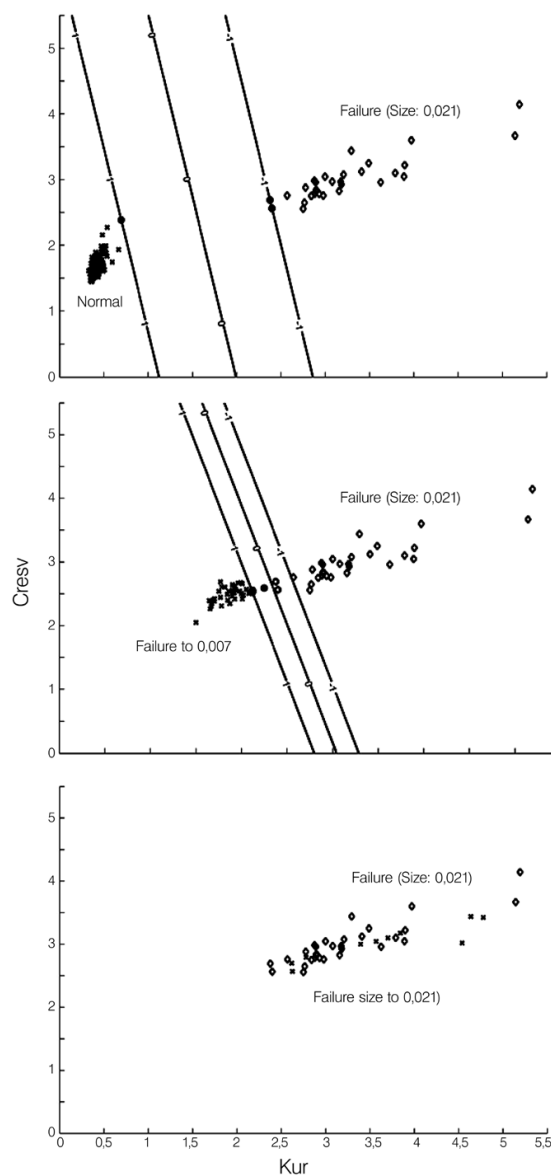


Figura 7. Evolución de la trayectoria con kernel polinomial SVM.

luada, puede estimarse la distribución de probabilidad condicional de un determinado estado de transición, dados los puntos del estado de transición para cualquier unidad 'individual' investigada.

El proceso de construcción de los intervalos de confianza necesarios es también sencillo. El proceso puede repetirse de manera recursiva para hacer predicciones con respecto a varios períodos de transición de estados secuenciales. Cuanto mayor sea el número de transiciones de estado deseado para una unidad, más estrictos serán los intervalos de predicción asociados con los estados finales de la unidad.

El objetivo aquí es modelar los vectores de tiempo estado-transición resultantes de los modelos de diagnóstico. Para el estudio del caso que nos

ocupa, mostrado en la Figura 7, se puede observar la evolución de las nubes de características.

La distancia media en la primera etapa entre los rodamientos normales y los rodamientos defectuosos es de ~2,8 en términos de valores de curtosis. Esta distancia se reduce a 0,1 en la segunda etapa y en torno a 0 cuando todos los rodamientos han fallado. La distancia de tiempo en términos de una característica es útil. Sin embargo, la fusión de las evoluciones de varias características revela una mayor precisión para procesar la velocidad de degradación de los vectores multidimensionales, donde se considerará una mayor información en dicho proceso de degradación. Si bien la evaluación poblacional es una de las ventajas más importantes de la estimación RUL mediante máquinas SVM, no deja de ser importante la evaluación individual de ítems de los que no existen elementos comparables y por tanto no responden a distribuciones de probabilidad y deben ser analizados individualmente. En este caso la estadística de modelado del RUL no corresponderá a distribuciones probabilísticas, sino a predicciones puras de la trayectoria estimando los puntos de intersección con los límites establecidos mediante filtros Kalman, ARMA u otros métodos de predicción no lineales y aplicables en cualquier espacio multidimensional, como el presentado por el mapa de características establecido.

Conclusiones

En éste trabajo se propone un nuevo método de predicción RUL inspirado por los clasificadores SVM. Los casos históricos de un sistema junto con los datos de condición durante la vida útil se utilizan para crear una clasificación por hiperplanos SVM. Para una prueba de evaluación del mismo sistema cuyo RUL debe ser estimado, la velocidad de degradación se evaluó mediante el cálculo de la distancia mínima definida sobre la base de las trayectorias de degradación; por ejemplo, el enfoque del sistema para el hiperplano que separa el buen y el mal estado de los datos en diferentes horizontes de tiempo. Por lo tanto, el RUL final de un componente específico puede ser estimado y la información global del RUL puede ser obtenida mediante la agregación de las estimaciones RUL múltiples utilizando un método de apreciación de la densidad.

Para una versión de prueba del mismo sistema cuyo RUL tiene que ser estimado, la velocidad de degradación es

evaluada mediante el cálculo de la mínima distancia definida basada en las trayectorias de degradación, es decir la aproximación del sistema al hiperplano que separa los buenos de los malos datos de condición en diferentes horizontes de tiempo. Por lo tanto, el RUL final de un componente específico puede estimarse y la información global RUL puede obtenerse mediante la agregación de múltiples estimaciones RUL utilizando un método de estimación de la densidad.

El modelo propuesto desarrolla un método de predicción RUL efectivo que contempla los múltiples desafíos en el complejo sistema de pronósticos. Las similitudes entre trayectorias de degradación se pueden comprobar con el fin de enriquecer las metodologías existentes en las aplicaciones de pronósticos. Los datos existen-

tes de CM para los rodamientos se utilizarán para verificar el modelo.

REFERENCIAS

- Dragomir O, Gouriveau R, Zerhouni N, Dragomir F (2007) Framework for a distributed and hybrid prognostic system. En *4th IFAC Conference on Management and Control of Production and Logistics*. Rumania.
- Dragomir O, Gouriveau R, Zerhouni N (2008) Adaptive neuro-fuzzy inference system for mid term prognostic error stabilization. *Int. J. Comp. Comm. Control* 3: 271-276.
- EN 13306 (2001) *Maintenance Terminology*. *European Standard*. CEN/TC 319. Comité Europeo de Normalización / AFNOR.
- Farrar CR, Lieven NAJ (2007) Damage prognosis: the future of structural health monitoring. *Phil. Trans. Math. Phys. Eng. Sci.* 365(1851): 623-632A.

- Hsu CW, Lin CJ (2002) A comparison of methods for multiclass support vector machines. *IEEE Trans. Neural Netw.* 13: 415-425.
- ISO 13381-1 (2004) *Condition monitoring and diagnostics of machines. Prognostics. Part 1: General Guidelines*. International Organization for Standardization. Ginebra, Suiza.
- Jardine AKS, Lin D, Banjevic D (2006) A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech. Syst. Sig. Proc.* 20: 1483-1510.
- Kim EY, Tan AC, Yang BS, Kosse V (2007). Experimental study on condition monitoring of low speed bearings: time domain analysis. En *Proc. 5th Australasian Congress on Applied Mechanics* (ACAM 2007). pp. 108-113.
- Sreejith B, Verma AK, Sridivya A (2008) *Fault diagnosis of rolling element bearing using time-domain features and neural networks*. IEEE - ICIS. Kharagpur, India.

RUL PREDICTION USING MOVING TRAJECTORIES BETWEEN SVM HYPER PLANES

Diego Galar-Pascual, Luis Berges-Muro, Ma. Pilar Lambán-Castillo, José Luis Huertas-Talón and Bernardo Tormos-Martínez

SUMMARY

A novel remaining useful life (RUL) prediction method inspired by support vector machines (SVM) classifiers is proposed. The historical instances of a system with life-time condition data are used to create a classification by SVM hyper planes. For a test instance of the system whose RUL is to be estimated, degradation speed is evaluated by computing the minimal distance defined based on the degradation trajectories, i.e. the system approach to the hyperplane that segregates good and bad conditions data at different time horizons. Therefore, the final RUL of a specific component can be estimated and global RUL information can then be obtained by aggregating the multiple RUL estimates using a density estimation method. The degradation process of a system may be affected by many unknown factors that complicate the degra-

dition behavior and also make it difficult to collect quality data. Due to lack of knowledge and incomplete measurements, certain important context information of the collected data might be missing. Therefore, historical data of the system with a large variety of degradation patterns is mixed together. With such data, learning a global model for RUL prediction becomes extremely hard. This has led to look for advanced RUL prediction techniques beyond the traditional prediction models. The proposed model develops an effective RUL prediction method that addresses multiple challenges in complex system prognostics. Similarities between degradation trajectories can be checked in order to enrich existing methodologies in prognostics applications. Existing condition monitoring data for bearings is used to validate the model.

CÁLCULO DA VIDA ÚTIL REMANESCENTE MEDIANTE TRAJETÓRIAS MÓVEIS ENTRE HIPERPLANOS DE MÁQUINAS DE SUPORTE VETORIAL

Diego Galar-Pascual, Luis Berges-Muro, Ma. Pilar Lambán-Castillo, José Luis Huertas-Talón e Bernardo Tormos-Martínez

RESUMO

Propõe-se um novo método de predição de vida útil remanescente (RUL) inspirado em classificadores de máquinas de suporte vetorial (SVM). Os dados históricos de condição de um sistema durante seu tempo de vida se utilizam para criar uma classificação mediante hiperplanos em SVM. Para estimar a RUL de um sistema, a velocidade de degradação se avalia calculando a distância mínima definida com base nas trajetórias de degradação; quer dizer, a aproximação do sistema ao hiperplano que segrega informação das condições boas e ruins em diferentes horizontes de tempo. Pode-se estimar a vida final de um componente específico, ou a informação da RUL de uma população ser calculada, mediante a agregação de múltiplas estimações RUL usando um método de estimação de densidade. A degradação de um sistema se vê afetada por muitos fatores desconhecidos que, além de complicar os comportamentos de degra-

dação, dificultam a coleta de dados com qualidade. Devido à falta de conhecimento e medidas incompletas, normalmente há carência de informação importante sobre o contexto dos dados recolhidos. Para isso são agrupados dados históricos do sistema com grande variedade de padrões de degradação, com os que a procura de um modelo global de predição RUL é extremamente difícil. Isto leva a buscar técnicas avançadas de predição além dos modelos tradicionais. O modelo proposto desenvolve um método eficaz de predição RUL que aborda múltiplos desafios em prognósticos de sistemas complexos. As similitudes entre trajetórias de degradação podem contrastar-se para enriquecer as metodologias atuais de prognose. Para verificar o modelo se utiliza monitorização de condições de rolamentos.