

WHITE PAPER

Cómo superar cuatro obstáculos habituales del mantenimiento predictivo con MATLAB y Simulink

El mantenimiento predictivo hace muchas promesas, desde reducir el tiempo de inactividad de las máquinas y eliminar el mantenimiento innecesario, hasta añadir nuevas fuentes de ingresos para proveedores de equipos con servicios posventa. Eminentemente, es posible conseguir estas ventajas siempre y cuando se superen los retos de ingeniería y comerciales que se presenten.

En este artículo, trataremos cuatro obstáculos habituales que impiden a las empresas implementar correctamente el mantenimiento predictivo, identificados tras más de 100 conversaciones con ingenieros y directores de ingeniería. Cada uno de estos retos tiene su correspondiente solución, que explicamos en este white paper.

1. No tenemos suficientes datos para crear un sistema de mantenimiento predictivo.

Muchos enfoques de mantenimiento predictivo se basan en algoritmos de machine learning, por lo que sí debe haber suficientes datos para crear un modelo preciso. En lo que respecta al mantenimiento predictivo, estos datos suelen proceder de sensores instalados en la maquinaria. Si los sensores son nuevos o el modo en que se registran las lecturas limita la información disponible, tendrá que buscar la mejor forma de acceder a datos suficientes para crear sus modelos.

Eche un vistazo más de cerca a su lista de fuentes de datos


Podría descubrir que su departamento no recopila suficientes datos para permitir la creación de un sistema de mantenimiento predictivo. Analice si otros departamentos también recopilan datos. Quizás el departamento de control no recopila suficientes datos, pero ¿qué pasaría si se combinaran con los datos procedentes de la división de servicios? Mirar más lejos dentro de su organización podría ser suficiente para satisfacer sus necesidades.

En función del tamaño de su empresa y el lugar que ocupe en la cadena de suministro, merece la pena analizar los acuerdos que ha establecido con sus proveedores o clientes. Una cooperación bilateral para prolongar el buen funcionamiento y la eficiencia de los componentes de los equipos puede crear una situación beneficiosa para todos que fomente el acceso a los datos entre ambas entidades comerciales. Este no será siempre el caso, pero es una fuente de datos potencial que merece ser considerada.

Cambie el modo en que se capturan los datos

Algunos sistemas operan en un modo de “abundancia o escasez” en el que no se recopilan datos hasta que se produce un fallo. Otros sistemas solo registran códigos de eventos y marcas de tiempo: los ingenieros reciben la notificación de que se ha producido un evento, pero no reciben los valores de los sensores en el momento del fallo. Aunque estos datos pueden resultar útiles para las tareas de diagnóstico, probablemente son insuficientes para desarrollar modelos capaces de predecir fallos.

Plantéese cambiar las opciones de registro de datos para que se registren más datos, quizás en una flota de prueba si no hay disponibles datos de producción. En función de la carga que soportan los dispositivos embebidos existentes, quizá sea posible reconfigurarlos para que recopilen y transmitan datos de los sensores o bien utilizar registradores de datos externos.



Configuración del registro de datos para recopilar y transmitir datos de sensores.

Utilice herramientas de simulación para sintetizar datos

Genere datos de prueba mediante herramientas de simulación y combínelos con los datos de sensores disponibles para crear y validar algoritmos de mantenimiento predictivo. Esto se consigue mediante la creación de modelos que permitan supervisar el sistema mecánico, el sistema eléctrico y otros sistemas físicos. Sintetice datos de muestreo (modelizando las lecturas de salida) y válidelos con datos medidos para garantizar que el modelo esté bien calibrado. Esto se puede hacer en primer lugar a nivel de componentes y posteriormente a nivel de sistema en caso de sistemas complejos.

Mazda simula datos para el desarrollo de motores

Mazda necesitaba definir planes de pruebas, desarrollar modelos estadísticos y generar calibraciones óptimas para su motor SKYACTIV-D. Así que desarrollaron modelos estadísticos para el motor SKYACTIV-G y realizaron una simulación hardware-in-the-loop (HIL) de la lógica de control del motor.

“Con los métodos tradicionales, obtener datos durante la calibración de un motor nuevo requería una enorme cantidad de pruebas... Así que reutilizamos los datos existentes y simulamos las respuestas, lo que nos permitió minimizar tanto la carga de trabajo para obtener datos de pruebas como la utilización de cámaras de pruebas.”

— Shingo Harada, Mazda

» [Leer la historia de usuario](#)

Consideraciones

A la hora de considerar los datos para un sistema de mantenimiento predictivo, primero analice los datos de forma anticipada para comprender qué características son importantes y cuáles pueden ser redundantes. En función del lugar donde almacene sus datos, puede salirle caro conservar una cantidad excesiva de datos que no se van a utilizar. Una vez que comprenda qué características de los datos son las más importantes, podrá tomar decisiones informadas sobre qué datos debe conservar y cuáles no. Una de las ventajas que ofrece una herramienta como **MATLAB**[®] es que está aislada del sistema de almacenamiento; si pasa de un almacenamiento local a otro en la nube, seguirá pudiendo ejecutar sus análisis con unos pocos cambios.

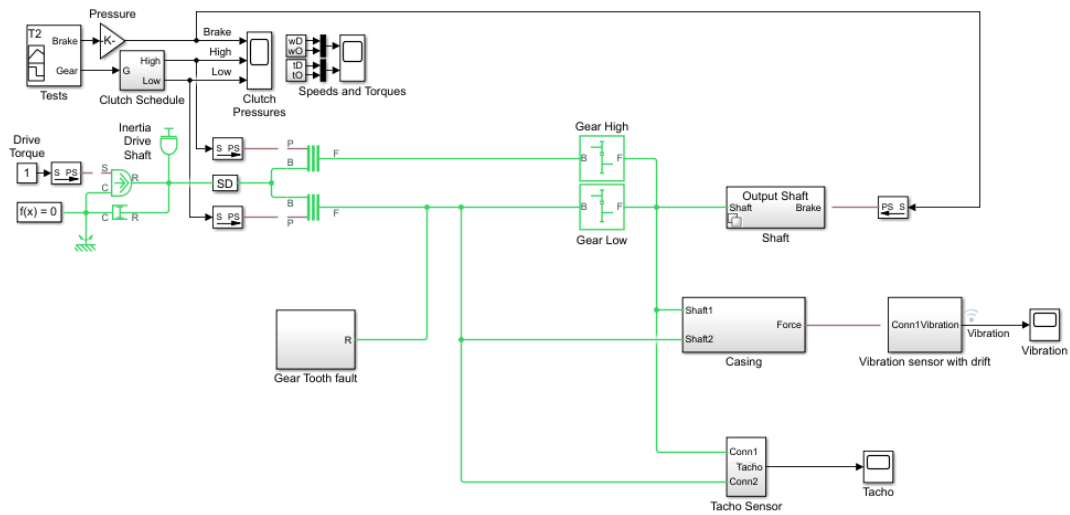
2. Nos faltan los datos de fallos necesarios para obtener unos resultados precisos.

Los datos de fallos son un elemento esencial para enseñar a los algoritmos a reconocer las señales de advertencia que activan el mantenimiento a tiempo. La ausencia de datos de fallos puede deberse a que el mantenimiento se realiza con tanta frecuencia que consigue que no se produzcan fallos, o bien a que el sistema es tan importante para la seguridad que no se puede permitir que falle. Para evitar que esto se convierta en una deficiencia catastrófica, usted y su equipo pueden simular datos de fallos y aprender a reconocer las señales de advertencia presentes en los datos de operaciones disponibles.

Genere datos de fallos

Un ingeniero con amplios conocimientos sobre cómo funcionan los componentes físicos será capaz de generar datos de fallos de muestra con las herramientas adecuadas. Con un producto de simulaciones como **Simulink**[®], un ingeniero puede crear o utilizar un modelo físico de la máquina del modo que hemos descrito antes en el primer reto. Algunas herramientas, como el análisis modal de fallos y efectos (FMEA), ofrecen puntos de partida útiles para determinar qué funciones se deben simular. Un ingeniero con suficientes conocimientos de dominio será capaz de incorporar estos comportamientos en el modelo en diversos escenarios, los cuales simularán fallos mediante el ajuste de temperaturas, tasas de flujo o vibraciones o la adición de un fallo repentino. Estos escenarios podrán entonces ser simulados, y los datos de fallos obtenidos se etiquetarán y almacenarán para su posterior análisis.

Productos como **Predictive Maintenance Toolbox**[™] simplifican estas tareas, como la **generación de datos de fallos**, y proporcionan combinadores de datos para gestionar y organizar múltiples conjuntos de datos.



Uso de Simulink para generar datos de fallos.

Airbus modela varios fallos de componentes para su avión comercial A380

Airbus necesitaba afrontar de forma segura los fallos en el complejo sistema de gestión de combustible de su avión A380. El equipo simuló fallos para perfeccionar el modelo. Tras las exitosas pruebas de vuelo, evaluaron las diferencias entre los datos medidos y los resultados de las predicciones para ajustar aún más los modelos.

“El diseño basado en modelos nos proporcionó una visibilidad avanzada del diseño funcional del sistema. También completamos la validación de requisitos antes de lo que era posible anteriormente y simulamos varios fallos simultáneos de componentes, así que ahora sabemos qué ocurrirá y confiamos en que la lógica de control se encargará de ello.”


— Chris Slack, Airbus

» [Leer la historia de usuario](#)

Comprenda los datos disponibles

Es posible que no disponga de datos de fallos, pero los datos de operaciones pueden mostrar tendencias de cómo una máquina se degrada con el paso del tiempo.

Analizar los datos de sensores sin procesar procedentes de un componente, un sistema o una máquina que tenga docenas o centenares de sensores puede ser una tarea abrumadora. Las técnicas estadísticas, como el análisis de componentes principales (PCA), pueden ayudar a reducir la dimensionalidad de estos conjuntos de datos y proporcionan una valiosa información sobre cómo funciona un equipo a lo largo del tiempo. El PCA es una de las muchas técnicas de aprendizaje no supervisado. El aprendizaje no supervisado es una rama del machine learning que intenta localizar patrones y tendencias en datos sin etiquetar. En función de los sensores que estén disponibles, determinados tipos de fallos pueden obligar a que se observen varios sensores simultáneamente para identificar un comportamiento no deseable. Las técnicas de aprendizaje no supervisado transforman los datos de sensores sin procesar en una representación dimensional más pequeña, que se puede visualizar y analizar más fácilmente que los datos sin procesar con una representación dimensional más grande.



Uso del análisis de componentes principales para visualizar la tendencia de un equipo antes del fallo.

Consideraciones

Intente mantener al mínimo el número de variables necesarias para obtener un modelo preciso. Puede resultar tentador incluir cada componente medido para asegurarse de que no se pierda nada, pero esto provocará un modelo de caja negra con una complejidad excesiva. Las técnicas como el PCA evitan esta situación y constituyen un método cuantitativamente riguroso para alcanzar esta simplificación.

3. Comprendemos los fallos, pero no podemos predecirlos.

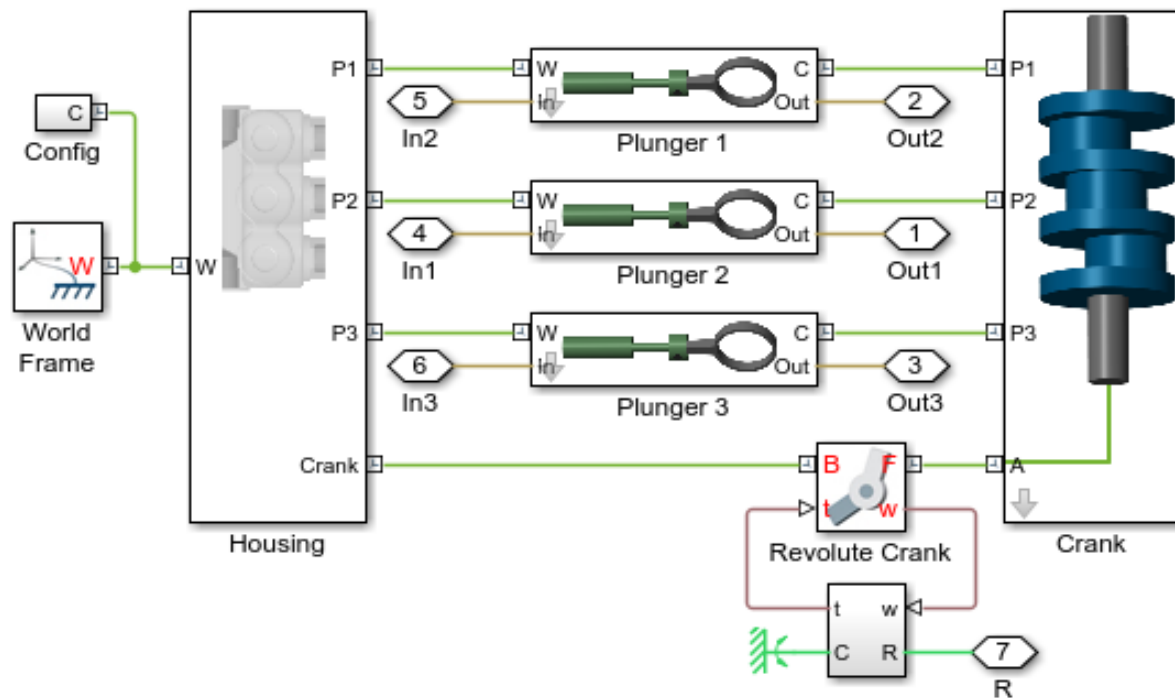
Comprender la causa de un fallo es importante para su empresa, pero hay una notable diferencia entre identificar qué ha fallado y saber cómo predecirlo. El análisis de causas raíz es una parte integral del conocimiento del dominio que, combinado con los algoritmos de mantenimiento predictivo, crea una aplicación efectiva de mantenimiento predictivo. Si la parte de la ecuación correspondiente a los algoritmos le resulta una tarea nueva y abrumadora, puede seguir estos pasos para reducir la curva de aprendizaje.

Defina objetivos

¿Cómo puede saber si un algoritmo de mantenimiento predictivo es mejor que el método que utilizaba antes? Es importante definir de antemano cuáles son sus objetivos (por ejemplo, una identificación de los fallos más rápida, unos ciclos más largos, un tiempo de inactividad más corto, etc.). Después debería pensar en cómo el algoritmo de mantenimiento predictivo afectará a estos objetivos. Crear un marco de prueba que sea capaz de probar un algoritmo y calcular su rendimiento en relación con sus objetivos permitirá unas iteraciones de diseño más rápidas. Ya no será cuestión de si un algoritmo nuevo es mejor que el método anterior, sino de si un algoritmo nuevo es mejor que otro en función de los objetivos previamente establecidos.

Empiece a pequeña escala

Si usted y su equipo ya conocen las causas que provocan los fallos, entonces ya dispone del conocimiento del dominio. Para practicar, elija un proyecto que haga uso de un sistema que conozca en profundidad. Asegúrese de comprender las características y factores que afectan al rendimiento del sistema, y cree un algoritmo de mantenimiento predictivo. Como punto de partida más sencillo, merece la pena considerar si el establecimiento de un umbral para una característica es un valioso indicador de mantenimiento (normalmente se realiza a través de gráficos de control). El conocimiento del dominio que tenga su equipo ayudará en la identificación de las componentes principales así como en el establecimiento de los valores del umbral, como un valor de seguridad que no se debe superar nunca. Además, puede probar modelos sencillos, como regresión lineal o logística, que son rápidos de adaptar y fáciles de interpretar. Una vez que usted y su equipo se sientan cómodos con la creación de algoritmos para un problema sencillo, puede aplicar ese conocimiento a sistemas más complejos.



Modelización de tres tipos de fallos: fugas en cilindros, toma de admisión bloqueada y fricción en cojinetes excesiva.

Gane confianza

Cuando los algoritmos de mantenimiento predictivo comiencen a dar resultados prometedores, utilice los datos actuales e históricos para probar y validar sus modelos antes de llevarlos a producción. Utilice el conocimiento del dominio dentro de su equipo para ajustar los modelos de forma que sean capaces de predecir distintos resultados en función del coste o la gravedad de tales resultados. Para validar aún más los modelos, genere datos de fallos que sean similares a condiciones históricas conocidas y pruebe el sistema. Este paso de validación hará que aumente su confianza en que el proceso funciona, ya sea destacando el lugar donde la simulación no coincide con la realidad y necesita más trabajo o confirmando la precisión del modelo.

Consideraciones

Como ocurre con cualquier tarea nueva, es importante no intentar hacerlo todo a la vez, lo cual solo provoca frustración cuando parece que el proyecto es demasiado complejo. Defina objetivos claros, empiece a pequeña escala, valide el modelo con los datos y realice iteraciones hasta que tenga plena confianza en los resultados. Repita este proceso para crear sistemas más complejos.


4. No sabemos cómo realizar el mantenimiento predictivo.

Cada tecnología nueva requiere una inversión que debe ser justificada. Idealmente, el tiempo necesario para sacar valor a la inversión debe ser lo más corto posible. Cuantificar el tiempo que tardará en recuperar la inversión es una tarea bastante difícil cuando existe incertidumbre sobre la rapidez con que usted y su equipo dominarán por completo estas nuevas habilidades. Si acaba de introducir el machine learning en su entorno, es natural que vea como un riesgo aquello que podría considerarse una aplicación avanzada. Sin embargo, puede dar pasos concretos para minimizar ese riesgo y empezar a aprovechar las ventajas de un modelo de mantenimiento predictivo funcional lo más rápidamente posible.

Trabaje con las herramientas que sus ingenieros ya conocen

En vez de intentar introducir una tecnología y una técnica nuevas, aproveche las nuevas capacidades del software que ya está instalado y céntrese en las técnicas nuevas. Algunas herramientas que ya utilizan los ingenieros, como MATLAB, disponen de capacidades de mantenimiento predictivo específicas, lo que les permite seguir trabajando en un entorno que ya conocen. Estas herramientas también proporcionan ejemplos y algoritmos de referencia para ayudar a los usuarios a disfrutar rápidamente del mantenimiento predictivo, así como soporte técnico, formación y consultoría. Esta orientación adicional puede fijar las bases para que usted y su equipo puedan estar seguros de que afrontan los problemas del mejor modo posible.

Aprenda el flujo de trabajo del mantenimiento predictivo



Aspectos básicos del flujo de trabajo del mantenimiento predictivo.

El primer paso para empezar a producir un modelo funcional es comprender el flujo de trabajo y reconocer los factores que podrían ralentizar el progreso. La tarea de creación y despliegue de algoritmos de mantenimiento predictivo se divide en cinco etapas:

1. Acceda a los datos de sensores

Los datos pueden proceder de varias fuentes, como bases de datos, hojas de cálculo o archivos web. Asegúrese de que los datos tengan el formato adecuado, incluidas marcas de fecha y hora. Es posible que los conjuntos de datos de gran tamaño no quepan en la memoria, por lo que necesitarán técnicas de procesamiento fuera de la memoria o bien un clúster. Los motivos de preocupación suelen estar relacionados con cómo organizar los datos para su análisis. Si no tiene suficientes datos, puede generarlos a partir de un modelo físico de la máquina para complementar el uso normal, los valores de parámetros variables, las distintas dinámicas del sistema o los fallos de señales.

2. Preprocese los datos

En el mundo real, los datos rara vez son perfectos; suelen tener valores atípicos y cierto nivel de ruido que debe eliminar para obtener una imagen realista del comportamiento normal. Si los datos proceden de distintas fuentes, también será necesario combinarlos. Si elimina las anomalías, plantéese si desea reemplazarlas con valores aproximados o trabajar con un conjunto de datos más pequeño. Entre los posibles temas sensibles se encuentran el ajuste del filtrado de ruido o de la configuración de valores atípicos y la comparación del efecto de diferentes filtrados sobre el rendimiento general del algoritmo.

3. Extraiga características

En vez de insertar los datos de sensores directamente en los modelos de machine learning, es habitual extraer las características a partir de los datos de sensores. Estas características capturan información de alto nivel en los datos de sensores; por ejemplo, medias móviles o contenido de frecuencia. Algunos ingenieros cuentan con amplia experiencia en estadísticas, procesamiento de señales y modelado de sistemas, por lo que el uso de herramientas con las que estén familiarizados para realizar técnicas de extracción de características simplifica este paso. Un enfoque iterativo —en el que se añadan las características, se entrenen los modelos nuevos y se compare su rendimiento— puede funcionar perfectamente aquí para determinar la eficacia de diferentes características sobre el resultado.

Baker Hughes extrae características para entrenar modelos destinados a sus equipos de extracción de petróleo y gas

Trabajando en MATLAB, el equipo de Baker Hughes analizó los datos importados de sus equipos de extracción de petróleo y gas para determinar qué señales presentes en los datos tenían mayor influencia en el desgaste de sus equipos. Este paso incluyó la realización de transformadas de Fourier y análisis espectral, así como filtrado de grandes movimientos en el camión, la bomba y el fluido para detectar mejor las pequeñas vibraciones de las válvulas y los asientos de las válvulas.


“MATLAB nos dio la capacidad de convertir datos que anteriormente eran ilegibles en datos con un formato utilizable, automatizar los pasos de filtrado, análisis espectral y transformada para varios camiones y regiones y, por último, aplicar técnicas de machine learning en tiempo real para predecir el momento ideal en que realizar el mantenimiento.”

— Gulshan Singh, Baker Hughes

» [Leer la historia de usuario](#)

4. Entrene el modelo

En este paso debe clasificar los datos como correctos o con fallos, establecer umbrales para los distintos estados (correcto/advertencia/fallo) y calcular la vida útil restante (RUL) de los componentes. Deberá crear una lista exhaustiva de escenarios de fallos que predecir, elegir los métodos de clasificación y simular los modelos. Las apps proporcionan interfaces gráficas para aplicar el machine learning que facilitan la puesta en marcha y comparan los resultados del entrenamiento de muchos tipos de modelos diferentes.



Entrenamiento de modelos predictivos que pueden calcular la vida útil restante y proporcionar intervalos de confianza en relación con la predicción.

5. Despliegue el modelo

Genere código y despliegue modelos como una aplicación en hardware. Los modelos se pueden desplegar en dispositivos embebidos convirtiéndolos a un lenguaje de bajo nivel como C, o bien se pueden integrar en otras aplicaciones en un entorno de TI. El problema aquí suele residir en la falta de familiaridad con la generación de código y la integración de TI. Existen herramientas capaces de empaquetar modelos automáticamente para su ejecución en un entorno de producción, como *MATLAB Compiler™* y *MATLAB Production Server™*. La consultoría puede resultar especialmente útil a la hora de intentar integrar estas aplicaciones en sistemas de TI.

Mondi desarrolla un sistema de mantenimiento predictivo

La planta de producción de plástico de Mondi Gronau funciona las 24 horas del día, los 7 días de la semana. Con la ayuda de los servicios de consultoría de MathWorks, crearon una aplicación de supervisión de estado y mantenimiento predictivo que permite a los trabajadores de la planta tomar medidas correctivas y evitar problemas graves. Completaron la aplicación en seis meses y ya se están ahorrando unos 200 000 euros al año.

“El soporte de los servicios de consultoría de MathWorks es uno de los mejores que he visto; los asesores son rápidos y cuentan con unos conocimientos excepcionales. Ya hemos visto una rentabilidad positiva en el ahorro de costes, y ahora tenemos más presupuesto y tiempo para completar más proyectos de machine learning que nos proporcionarán unos beneficios similares.”

— Dr. Michael Kohlert, Mondi

» [Leer la historia de usuario](#)

Consideraciones

Algunas empresas necesitan informes diarios sobre sus máquinas, mientras que otras necesitan procesamiento en tiempo real. Piense en el nivel de supervisión que necesita su empresa. Tenga en cuenta también los tipos de datos que recopila: ¿son datos de señales, imágenes o textos y podrían resultar útiles para la predicción de fallos? Necesitará potencia de cálculo suficiente para dar cabida a grandes volúmenes de datos. Por último, piense en cómo necesita presentar los resultados obtenidos, en cuánta información necesita sobre cómo se determinan las advertencias y en quién necesita recibir estas notificaciones.

Conclusión

El mantenimiento predictivo es un objetivo alcanzable que puede conseguirse con las herramientas, la orientación y la motivación adecuadas. Encuentre las características, modelos y métodos que funcionan para su negocio y realice iteraciones hasta que obtenga el resultado que desee. Y recuerde que no tiene que hacerlo todo solo.

Más información

- [Mantenimiento predictivo con MATLAB: Evite costosos fallos de equipos gracias a la analítica de datos de sensores](#) - Ebook
- [Machine Learning con MATLAB](#) - Ebook
- [Consultoría de MathWorks para mantenimiento predictivo](#) – Descripción general del servicio