

Mantenimiento Predictivo basado en monitoreo de vibración avanzado en línea

Mateo Peñaranda Valero, CRL¹
Bogotá D.C. – Colombia
Febrero, 2019

Resumen

Con el fin de realizar realmente mantenimiento predictivo en equipo rotativo es necesario utilizar herramientas de *machine learning* que permitan llevar a cabo monitoreo avanzado por condición, usando por ejemplo análisis de vibración. Esto permite obtener la predicción requerida, incluyendo diagnóstico en línea y estimación del tiempo hasta la falla crítica del componente o activo. Este documento presenta un resumen de las herramientas disponibles en la industria actualmente para dicho fin, así como nociones del futuro de la tecnología en el marco de la Cuarta Revolución Industrial o Industria 4.0.

Introducción

En la ingeniería de confiabilidad y mantenimiento, llevamos cerca de 30 años hablando de mantenimiento predictivo sin tener la tecnología ni el conocimiento real para hacerlo. Hemos convertido un anhelo en algo que creemos real. Confundimos típicamente un programa de mantenimiento preventivo basado en condición con un programa predictivo.

Hay que tener en cuenta que para poder realmente hablar de predicción tenemos que conocer las causas de la falla incipiente y el tiempo de vida remanente. Sin estos dos

elementos: diagnóstico y pronóstico, no podemos hablar de predicción. Pensemos en una vidente que sólo nos diga: ¡usted va a morir! Pero no nos diga las causas ni nos dé un tiempo estimado. ¿Diríamos que esta persona está prediciendo algo?

Teniendo en cuenta lo anterior, y entendiendo realmente ahora qué es el mantenimiento predictivo, han surgido en los últimos años algunas herramientas tecnológicas que permiten hacerlo realidad. De allí nacen por ejemplo los últimos avances de *machine learning* supervisado y reforzado, *Deep learning* y la utilización de redes neuronales complejas aplicadas al mantenimiento y la gestión de activos, como parte de la revolución industrial reciente (Industria 4.0).

En el caso del análisis de vibración, la idea detrás de estos sistemas es extraer *features*², bien sea dentro de regiones del espectro (sub-armónicos, armónicos, etc.), datos globales (RMS, cresta, peak-to-peak, etc.), por la onda en el tiempo, orbitas, etc. Algunos ejemplos de *features* son: valor amplitud RMS, valor amplitud 1X, frecuencia de impactos en la onda en el tiempo. Sin embargo, también pueden existir *features* abstractos obtenidos a través de análisis y procesamiento de las señales con la utilización de herramientas computacionales, que se obtienen al correlacionar características

¹ CRL: Certified Reliability Leader by the Association of Asset Management Professionals

² Features: Características de la señal de vibración que pueden ser relacionadas con fallas del equipo

de la información con modos de falla del componente o equipo analizado.

Dependiendo entonces las características del activo y el modo de falla que se quiere detectar, se definen los *features* que aplican y los rangos para las alertas. Estas alertas se definen típicamente en dos niveles de acuerdo a su intensidad: incipiente (falta o potencial) y crítica (falla). Estos niveles de alarmas pueden venir de la experiencia aportada por especialistas en la materia, por bases de datos y/o por análisis computacional con datos históricos relacionados con estados normales y de fallas de los equipos.

Posteriormente, y antes de poner el sistema en productivo, se realiza un proceso de validación o entrenamiento, donde la idea es corroborar la validez del modelo hasta alcanzar un error inferior al definido. Esto se logra a través de un proceso de iteración donde se ajustan los “pesos” del modelo, que son las variables o coeficientes que lo definen. Esto se puede hacer con un paquete de datos conocidos o con datos en línea durante un periodo de prueba.

Dependiendo de si estos procesos se realizan completamente por una máquina (*features* abstractos) o de manera manual, se conocen como *machine learning* o *deep learning*, respectivamente.

En cualquiera de los casos, el resultado es un modelo que puede diagnosticar las fallas, cuando se alcanza la primera alarma, y de calcular la probabilidad de falla o tiempo hasta

que la condición alcance el segundo nivel de alarma.




Fig 1. Machine learning - Deep learning [2]

Adicional a esto, los modelos pueden contar con características de refuerzo. En donde complementan la toma de decisiones con variables externas, como pueden ser: variables de proceso (flujos, temperaturas, presiones, etc.) o incluso información comercial y de mercado. Esto permite entonces tener una herramienta para toma de decisiones mucho más robusta, gracias a la interconexión de las diferentes áreas y procesos.

Sin embargo, como estas son todavía herramientas en desarrollo existe una brecha entre el conocimiento académico/investigativo, el mercado y la industria. Teniendo en cuenta que la industria está siempre un paso atrás en esta curva (IoT vs IIoT³).

Por este motivo, los sistemas convencionales actuales para análisis de vibración tienen limitaciones que hacen que no sean adecuados para suplir la necesidad de la industria. El principal problema radica en la filosofía para detección de fallas, que se basa en los valores *overall*⁴ de vibración, ya que evolucionaron de las alarmas típicas de protección de equipos.

³ IoT: Internet de las Cosas) / IIoT: Internet Industrial de las Cosas

⁴ Overall = $\sqrt{\sum_{i=1}^N A_i^2}$ (A: amplitud, i: frecuencias) – En el espectro (amplitud vs frecuencia)

Esto hace que en muchos de los casos no se puedan detectar fallas incipientes de manera adecuada y se lancen alarmas cuando la falla ya está en una etapa avanzada o incluso cuando la falla es inminente. Haciendo entonces que la mayoría de las veces, estas herramientas sean utilizadas para análisis post-mortem (análisis de causa raíz) con la ayuda de personal especializado. Si se quisiera utilizar esta tecnología para realmente monitorear la condición de los equipos en línea sería una tarea con alta demanda de horas especialista y poco eficiente, teniendo en cuenta la gran cantidad de señales y la alta frecuencia de muestreo de los activos en las plantas industriales modernas.

No obstante, existe ya una herramienta para la industria pesada que permite realizar monitoreo de vibración avanzado en línea para equipo rotativo con diagnóstico y pronóstico integrado. Esta herramienta software patentada se llama EtaPRO™ Predictor y está integrada con las demás herramientas de este software (EtaPRO⁵) para poder soportar el análisis con variables externas: temperaturas, flujos, costos, mercado y demás datos de proceso. En las siguientes secciones del documento se amplía la información de esta tecnología.

Descripción del sistema

Para suplir las necesidades actuales de la industria, y tener un sistema que permitiera hacer un monitoreo de los activos basado en la vibración espectral y por *features* (no solo *overall*), realizar diagnóstico en línea y llevar a cabo un pronóstico de la vida útil hasta que la falla sea crítica, GP Strategies lanza EtaPRO Predictor.



Fig 2. Comparación EtaPRO Predictor y otras tecnologías

Como se puede ver en la Fig 2, EtaPRO Predictor es una herramienta avanzada para monitoreo por vibración que utiliza la tecnología de síntomas de falla y permite adelantarse a las mismas para poder tener tiempo de verificación y planeación del mantenimiento. Permitiendo así tener ahorros económicos muy significativos por aumento en mantenimiento predictivo (contra correctivo), así como ahorros relacionados con mejoras en confiabilidad y disponibilidad: prevenir salidas forzadas y fallas secundarias, disminuir los tiempos de paradas programadas, entre otros. Adicional a esto, se logran ahorros por disminución de los costos de repuestos (almacenamiento y pedidos de emergencia), una mejora en la seguridad de la planta y un mejor ambiente de trabajo, al realizar una mejor planeación y programación.

Los modelos, gemelos digitales, se construyen de manera semiautomática por el mismo software. Tomando información de diseño del activo y sus componentes para definir la configuración inicial del modelo basado en los

⁵ EtaPRO: herramienta software instalada en más de 2000 plantas industriales en más de 50 países (<http://www.etapro.com>).

features de detección contenidos en la base de datos del programa.

Posteriormente, con la información histórica de las señales asociadas al activo (no solo vibración) el sistema define los diferentes estados de operación del equipo (arranque en frío, arranque en caliente, cargas parciales, carga máxima, operación estable, etc.) y se generan *features* específicos para cada una de estas secciones.




Fig 3. Diferenciación de comportamiento por estados

Este proceso es fundamental para poder evitar falsas alarmas a futuro, ya que los niveles de alarma y el comportamiento del sistema cambia significativamente entre un estado y el otro.

A continuación, se utiliza la ayuda de especialistas en la materia para calibrar el modelo y ajustar los pesos del mismo, así como los rangos de alarma con la ayuda del software y las bases de datos que contiene.

Típicamente, este proceso de entrenamiento y prueba del modelo se aprovecha para generar interacción entre los especialistas y el personal de planta, en un esfuerzo por realizar una transferencia de tecnología efectiva. Esto incluye actividades de comisionamiento en campo, entrenamiento de los usuarios, monitoreo compartido, resolución de dudas y acompañamiento en la operación continua.

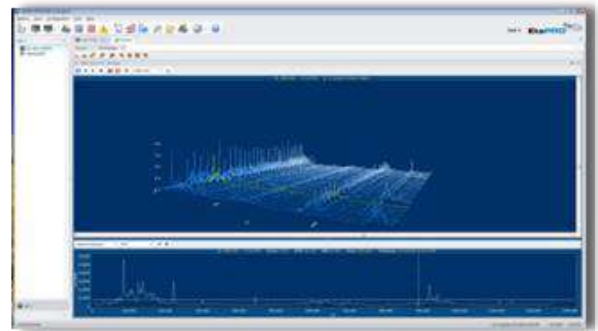


Fig 4. Análisis de señales EtaPRO Predictor

Una vez construido el modelo y puesto en línea, el sistema utiliza los rangos de alarma incipiente y crítica, para lanzar alertas, diagnósticos y pronósticos de falla. Todo esto basado en las señales de vibración y complementado con las demás señales de la planta (temperaturas, flujos, presiones, etc.).

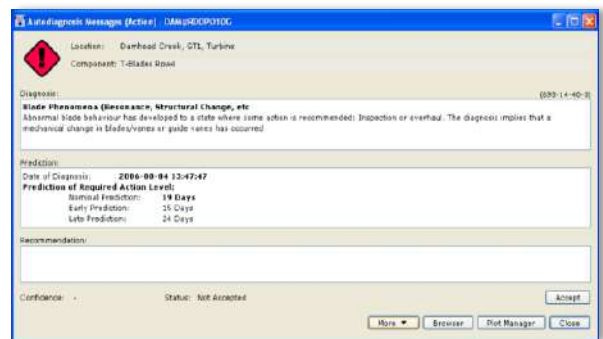


Fig 5. Autodiagnóstico EtaPRO Predictor

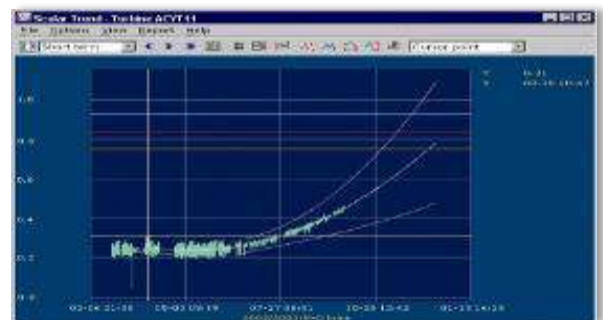


Fig 6. Pronóstico EtaPRO Predictor

Esto permite que el personal de la planta se concentre solamente en las alarmas que lanza el sistema, con la seguridad que todos los demás activos monitoreados están operando de manera

normal. Permitiendo así que personal con entrenamiento básico pueda hacerse cargo del monitoreo de todos los activos de la planta con una dedicación de tiempo mínima.

Inclusión del sistema en el P.G.A.

Es importante aclarar en este punto, que esta herramienta software debe estar integrada y alineada con la política interna de la compañía y con los procedimientos de la planta, incluyendo el PGA (Plan de Gestión de Activos).

Este componente tecnológico debe ser integrado junto con una mejora en procedimientos y entrenamientos, así como un manejo del cambio adecuado.

Sin estas previsiones, no es posible garantizar el máximo aprovechamiento del software ni garantizar el éxito de la iniciativa.

Además, debe realizarse preferiblemente en etapas que permitan optimizar procesos poco a poco con la utilización de la tecnología. Algunos ejemplos son: generación automática de avisos de inspección y ordenes de trabajo, análisis de causa raíz automático, toma de decisiones con árboles de decisión automáticos, entre otros.

De igual forma, es indispensable incluir este sistema dentro del plan de entrenamientos y capacitaciones de la compañía. Permitiendo además que el personal de la planta se adueñe de la tecnología y logre obtener el mayor provecho de la misma. Esto requiere entrenamientos a todos los niveles, talleres de trabajo, actividades de monitoreo apoyadas por especialistas, proceso de re-entrenamiento, entre otros.

No es necesario para la utilización de la herramienta que los usuarios cuenten con algún tipo de certificación, pero estas siempre son recomendadas (nivel II o superior).

Futuro de la Tecnología

Avances tecnológicos

En este punto, siguiendo la misma línea ilustrada en este documento, la tecnología seguirá creciendo principalmente en las herramientas de creación de sistemas y modelos, que permitan disminuir los costos de los productos y crear soluciones más robustas y confiables.

La opinión generalizada es que las actividades de análisis final de la información y toma de decisión seguirán siendo realizada por humanos en las próximas décadas y la realización de los trabajos técnicos especializados también, solo que asistidos por robots.

Adaptación

Según lo concluido en el Foro Económico mundial más reciente [1], para el 2022 el 21% de los trabajos actuales van a ser redundantes y podrá ser realizado por un robot o una máquina. Algunos ejemplos son: digitadores de información, personal de transporte, operarios básicos de planta, etc. Sin embargo, van a surgir 27% de nuevos trabajos como: ingenieros de robótica, diseñadores de soluciones, profesionales de innovación, etc.




Fig 7. Futuro de los trabajos al 2022 [1]

Por esta razón, en la industria colombiana debemos hacer un esfuerzo significativo para adaptarnos a los cambios rápidamente y lograr insertarnos estratégicamente en la nueva cadena de valor. Trabajando tanto en el desarrollo de tecnología como en el desarrollo de competencias en los profesionales.

Esto último se consigue adquiriendo tecnología de punta actual, que permita a la industria nacional adaptarse a las últimas tendencias y así desarrollar desde este punto. Subiéndonos a la ola tecnológica y no persiguiéndola desde atrás o esperando que nos arrastre.

Requiriéndose entonces trabajo en conjunto entre el Gobierno, las instituciones educativas, la industria y las asociaciones.

Conclusiones

-Para poder realizar mantenimiento predictivo deben utilizarse herramientas tecnológicas que permitan realizar diagnóstico en línea y estimación del tiempo hasta la falla.

-Los sistemas convencionales de análisis de vibración no cuentan con estas capacidades desarrolladas de manera correcta.

-En el caso del análisis de vibración, este debe estar basado en los *features* de la señal y no solo en los valores *overall*.

-Una de las herramientas tecnológicas disponibles es EtaPRO Predictor (by GP Strategies), utilizada para industria pesada con aplicación en todo el mundo y desarrollo desde los años 80.

-La utilización de estas herramientas permite generar grandes beneficios a las industrias que la utilizan con aumentos en eficiencia, disponibilidad y confiabilidad, que redundan en ahorros económicos y retorno de la inversión en el primer año, típicamente.

-Esta revolución tecnológica va a traer disminución en los costos de las herramientas y más robustez y confianza en las mismas. Automatizando la creación de modelos, su entrenamiento y calibración para permitir menos supervisión y más exactitud.

-Estos avances harán que algunos trabajos existentes sean redundante y obsoletos, principalmente los relacionados con toma de datos y procesamiento de la información, pero generaran también la creación de nuevos trabajos, relacionados con operación y mantenimiento de la tecnología, así como análisis de datos y toma de decisiones.

-Es responsabilidad de todos (instituciones gubernamentales, instituciones académicas, industria y asociaciones) desarrollar estrategias que nos permitan adaptarnos a estos cambios y ser competitivos bajo la nueva realidad. Buscando formas de aportar a la cadena de valor y capacitando nuestros profesionales siguiendo los perfiles requeridos.

Bibliografía

[1] World Economic Forum, “Future of Jobs Survey”, Davos-Klosters (Switzerland), 2018.

[2] Universidad de los Andes, “Curso Gestión de Activos, mantenimiento y confiabilidad”, Profesor Enrique López Droguett PhD, Bogotá (Colombia), 2018.

[3] Pugliano, “The Robots are coming: a human’s survival guide to profiting in the age of automation”. Berkeley, CA. Ulysses Press, 2017.

Mateo Peñaranda Valero

Ingeniero mecánico de la Universidad de los Andes, Líder de Confiabilidad Certificado por la Asociación Americana de Gestión de Activos (CRL – AMP) y Analista de Vibración CAT-II. Experiencia en construcción, comisionamiento, operación y mantenimiento de plantas de generación de energía eléctrica. Experiencia reciente en implementación de sistemas de monitoreo por rendimiento y condición en ciclos Rankine, ciclos combinados e hidroeléctricas; más de 50 unidades de generación en 10 países, entrenando más de 500 personas en este proceso.

Teléfono Oficina: 7430782

Teléfono Celular: 3142451045

Dirección Oficina: Carrera 9A # 99-02

Email: mpenaranda@gpstrategies.com

Bogotá – Colombia