



Tecnologías de Inteligencia Artificial (AI) en el Mantenimiento de Activos del Sector Eléctrico



Banco Interamericano de Desarrollo

Mayo 2023

Copyright © **2023** Banco Interamericano de Desarrollo (BID). Esta obra se encuentra sujeta a una licencia Creative Commons CC BY 3.0 IGO (<https://creativecommons.org/licenses/by/3.0/igo/legalcode>). Se deberá cumplir los términos y condiciones señalados en el enlace URL y otorgar el respectivo reconocimiento al BID.

En alcance a la sección 8 de la licencia indicada, cualquier mediación relacionada con disputas que surjan bajo esta licencia será llevada a cabo de conformidad con el Reglamento de Mediación de la OMPI. Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la Comisión de las Naciones Unidas para el Derecho Mercantil (CNUDMI). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID, no están autorizados por esta licencia y requieren de un acuerdo de licencia adicional.

Note que el enlace URL incluye términos y condiciones que forman parte integral de esta licencia.

Las opiniones expresadas en esta obra son exclusivamente de los autores y no necesariamente reflejan el punto de vista del BID, de su Directorio Ejecutivo ni de los países que representa.



Tecnologías de Inteligencia Artificial (AI) en el Mantenimiento de Activos del Sector Eléctrico

Editores

José Luis Irigoyen

Arturo Alarcón

Eric Daza

Autores

José Luis Galo

Enrico Di Martino

Jesús María Velásquez Bermúdez

Alberto Delgadillo Gomez

Mayo, 2023

Agradecimientos

Este informe es parte de la agenda de conocimiento desarrollada por la División de Energía del Banco Interamericano de Desarrollo, la cual tiene por objetivo desarrollar nuevos productos de conocimiento y programas de asistencia técnica para los países de América Latina y el Caribe. Los productos de conocimiento generados tienen la intención de informar, guiar y ofrecer un menú de recomendaciones a los hacedores de políticas y participantes activos en los mercados energéticos, incluidos los consumidores, las empresas de servicios públicos y los reguladores.

El informe fue elaborado bajo la dirección general de Marcelino Madrigal (Jefe de la División de Energía). El líder del equipo de trabajo es José Luis Irigoyen. Los principales autores del informe son José Luis Galo, Enrico Di Martino, Jesús María Velásquez Bermúdez y Alberto Delgadillo Gomez de RINA Consulting, Inc. Los miembros del equipo de trabajo incluyen a Arturo Alarcón y Eric Daza. El equipo agradece a Lenin Balza, Wilkferg Vanegas Rico y Augusto Cesar Bonzi Teixeira por sus comentarios y revisión. El equipo agradece el apoyo financiero de la cooperación técnica “Acelerar la digitalización en el sector energético” (RG-T3820).

Contenido

Lista de Acrónimos	7
Resumen Ejecutivo	9
1 Introducción	11
1.1 Optimización Integrada de la Empresa	11
1.2 El Sector Eléctrico	12
1.2.1 Estructura	12
1.2.2 Reglamentación	12
1.2.3 Mantenimiento de Infraestructura Eléctrica	13
1.3 Modelamiento del Mantenimiento de la Infraestructura Eléctrica	14
1.3.1 Marco de Referencia	14
1.3.2 Analíticas Avanzadas: Predictiva y Prescriptiva (Optimización)	15
2 Industria 4.0 (I4.0)	16
2.1 Sistemas Ciberfísicos (CPS)	16
2.2 IoT, Big-Data y Smart Metering	17
2.3 Digitalización en integración de las cadenas de valor en el sector eléctrico	17
2.4 Digitalización de Productos y Servicios	19
2.4.1 Gemelos Digitales	19
2.4.2 Realidad Virtual y Realidad Aumentada	19
2.5 Marco de Referencia Analítico	20
2.5.1 Analítica Avanzada y Robots Cognitivos	20
2.5.2 Transformación Digital: Mantenimiento de Activos Eléctricos en I4.0	21
2.5.3 Inteligencia artificial (IA) y toma de decisiones en I4.0	21
3 Teoría de Gestión de Activos	23
3.1 Mantenimiento de Infraestructura Eléctrica	23
3.1.1 Marco de Referencia y Conceptualización	23
3.1.2 Teoría de Gestión de Activos	23
3.2 Ingeniería de Confiabilidad	25
3.3 Tipos y Decisiones de Mantenimiento	25
3.3.1 Prácticas de Mantenimiento	26
3.3.2 Mantenimiento Basado en la Condición (CBM)	26
3.3.3 Mantenimiento Pronóstico de la Salud (PHM)	27
3.3.4 Modelamiento de los Activos en sistemas PHM	28
3.3.5 Sistemas PHM “Cerrados”	29
4 Modelamiento de las Componentes: PHM Predictivo y de Pronóstico	31
4.1 Enfoques en PHM	31
4.2 Analítica Predictiva	31
4.2.1 Muestra Histórica	32
4.2.2 Estimación de Estado	32
4.2.3 Aplicación de la Inteligencia Artificial al Sector Eléctrico	33
4.3 Proceso PHM	34

Tecnologías de Inteligencia Artificial (AI) en el Mantenimiento de Activos del Sector Eléctrico

4.3.1	Validación de Datos	34
4.3.2	Diagnostico	34
4.3.3	Pronóstico	34
4.4	Modelado PHM del RUL	35
5	Optimización de la Red de Activos Eléctricos: PHM Prescriptivo y de Optimización	36
5.1	Optimización del Mantenimiento	36
5.2	Analítica Prescriptiva.....	36
5.2.1	Modelos Mentales.....	37
5.2.2	Simulación.....	37
5.2.3	Metaheurísticas.....	37
5.2.4	Machine Learning.....	38
5.2.5	Optimización Matemática.....	38
5.3	Gestión de Riesgos	38
5.4	Modelamiento de los Componentes	39
5.5	Optimización Individual de Activos.....	39
5.6	Optimización de la Red de Activos	39
5.7	Tabla de Resumen	41
6	Conclusiones.....	42

Anexos

- A. Casos de Uso en el Sector Eléctrico
 - B. Guía de Implementación de un Sistema PHM
 - C. Referencias Bibliográficas
-

Lista de Acrónimos

Acrónimo	Nombre
ANN	Artificial Neural Network
AR	Augmented Reality
BID	Banco Interamericano de Desarrollo
BVLOS	Beyond the Visual Line of Sight
CAPEX	Capital Expenditures
CBM	Condition Based Management
CMS	Condition Monitoring Systems
CNN	Convolutional Neural Networks
CPS	Cyber-Physical System
CR	Cognitive Robots
CVaR	Conditional Value-At-Risk
DBN	Deep Belief Networks
DGA	Dissolved Gas Analysis
DNN	Deep Neural Network
DSA	Distribution System Automation
DT	Digital Twin
DTOM	Digital Terrain Model
EOL	End of Life
ESA	Electricity Storage Association
EWEA	European Wind Energy Association
EWO	Enterprise-Wide Optimization
FDD	Fault Detection and Diagnosis
GAN	Generative Adversarial Networks
GD	Generación Distribuida
HI	Health Indicators
HSSB	High-Speed Shaft Bearing
IA	Inteligencia Artificial
IEA	International Energy Agency
IoT	Internet of Things
LATAM	América Latina
LFP	Lithium Iron Phosphate
LIDAR	Light Detection and Ranging
ML	Machine Learning
MP	Mathematical Programming
NREL	National Renewable Energy Laboratory

Acrónimo	Nombre
NT	Nota Técnica
OANM	Optimization of Asset Network
OIAM	Optimization of Individual Asset Maintenance
OPEX	Operational Expenditures
OTF	Outdoor Test Facility
PHM	Prognostic Health Maintenance
PNN	Probabilistic Neural Net
PSC	Power Supply Company
PSVM	Plane-Based One-Class Support Vector Machine
RNN	Recurrent Neural Networks
RUL	Remaining Useful Life
SCADA	Sistema de Control Supervisado y Adquisición de Datos
SDM	Single Diode Model
SG	Smart Grid
SIG	Sistemas de Información Geográfica
SVDD	Support Vector Data Description
SVM	Support Vector Machine
S&OP	Sales & Operations Planning
TBM	Time Based Maintenance
UAS	Unmanned Aerial Systems
UAV	Unmanned Aerial Vehicles
VLOS	Visual Line of Sight
VR	Virtual Reality
WOA	Whale Optimization Algorithm
WTG	Wind Turbine Generator

Resumen Ejecutivo

La transformación digital o digitalización de la sociedad está teniendo lugar gracias a la convergencia de nuevas tecnologías como la inteligencia artificial (IA), IoT, Big Data, gemelos digitales, realidad aumentada, 5G, avances en ciberseguridad, etc. en relación con la Industria 4.0, y la mayor capacidad de computación (computación en la red y en el borde). La digitalización está continuamente brindando soluciones y nuevas oportunidades de mejora en todos los ámbitos y sectores, ofreciendo soluciones a necesidades y problemas hasta ahora imposibles de abordar.

El presente estudio ofrece una visión global sobre la importancia de abordar el Mantenimiento de Activos del sector eléctrico, en el marco de las Tecnologías de Inteligencia Artificial y nuevas tecnologías, mediante la implementación de metodologías de analítica avanzada (Mantenimiento Pronóstico de la Salud, Prognostic Health Maintenance o PHM) para lograr una posición competitiva en términos de minimización de costes y maximización de beneficios.

Los beneficios inmediatos de la Prognostic Health Maintenance (PHM) son la reducción de acciones correctivas y sus costes asociados, gracias a un modelado de vida útil que anticipa fallos y define acciones de mantenimiento optimizadas. Se estima que la aplicación de mantenimiento de PHM predictivo, de pronóstico y de optimización supone en media un beneficio (o ahorro en costes de mantenimiento) de entre un 18-25% en comparación con mantenimientos tradicionales preventivos y correctivos. Los beneficios debidos al PHM y las áreas más impactadas por estos beneficios se describen en esta nota.

Existe un fuerte vínculo entre la PHM y la digitalización, ya que las tecnologías digitales son esenciales para permitir prácticas eficaces de PHM. El uso de sensores, análisis de datos y algoritmos de aprendizaje automático pueden ayudar a recopilar y analizar datos en tiempo real, lo que permite la detección temprana de anomalías y la predicción de posibles fallos antes de que se produzcan. Esto puede mejorar significativamente la fiabilidad y la seguridad de los sistemas.

Actualmente existen y se desarrollan multitud de aplicaciones de IA en combinación con la analítica avanzada para facilitar labores de operación y mantenimiento de activos eléctrico.

Actualmente, varias firmas de desarrollo de plataformas (software) posibilitan la supervisión remota en tiempo real de redes de distribución y transmisión aplicando tecnologías IoT y sensores para la recopilación y análisis de datos

La transformación de las redes eléctricas en redes inteligentes permite que éstas sean capaces de procesar e integrar y tele gestionar acciones realizadas por los agentes conectados a ellas, incluyendo generadores, distribuidores y consumidores.

El concepto de uso de las nuevas tecnologías (IA, IoT, Big Data) al servicio de las analíticas avanzadas (predictiva y prescriptiva) para la toma de decisiones inteligentes en el mantenimiento de la infraestructura eléctrica, tiene infinidad de aplicaciones dentro del mismo sector eléctrico en otros ámbitos de la organización, asociadas indirectamente con el mantenimiento inteligente.

A medida que crezca la generación distribuida, los usuarios participarán activamente en la producción de electricidad (productores o consumidores según la ventana de tiempo; también llamados prosumidores). La IA simplificará la elección de los mejores momentos para que la generación distribuida aporte energía a la red en lugar de consumirla, a medida que estos prosumidores (por ejemplo, energía solar en tejado) crezcan en importancia dentro del sistema. El auge de las energías renovables intermitentes, la generación distribuida, incluidos los

prosumidores, y las nuevas tendencias del lado de la demanda, como el auge de los vehículos eléctricos, pueden ser equilibrados por los productores tradicionales y los operadores del sistema con la ayuda de la IA.

Se presentarán las metodologías analíticas predictivas empleadas para conocer el comportamiento de los activos a partir del conocimiento de la salud, de sus componentes y una visión general del uso de las metodologías analíticas prescriptivas para optimizar las decisiones relacionadas con las componentes, los activos y la red de activos.

Con la presente NT se pretende mostrar a los agentes públicos, propietarios, operadores y gerentes de activos del sector eléctrico, la importancia de la implementación del mantenimiento inteligente con el uso de analíticas avanzadas y las nuevas tecnologías y se invita y recomienda a profundizar más en este campo contactando con expertos del sector y buscando financiación adecuada.

1 Introducción

El mantenimiento inteligente de activos eléctricos debe abordarse con una visión holística de la organización (logística, compras, finanzas, mercado, oferta y demanda, etc.), integrando variables de otros campos de la empresa en el proceso de optimización y toma de decisiones de mantenimiento, pudiendo así anticipar y tener en cuenta el impacto de dichas operaciones a nivel global de la organización.

En este primer capítulo se presenta dicha visión global de la planificación de activos (en inglés conocida como Enterprise-Wide Optimization, EWO) y su integración con la Industria 4.0¹ (I4.0 o Cuarta Revolución Industrial) y con la Analítica Avanzada.

La visión holística de planificación del mantenimiento, la integración de nuevas tecnologías (por ejemplo, inteligencia artificial, redes neuronales, machine learning, IoT, Big Data, etc.) y de las analíticas avanzadas para el mantenimiento inteligente de activos, se aplica a cualquier tipo de organización, y en concreto, a empresas del sector eléctrico y energético, a quien va dirigida el presente estudio.

El segundo capítulo de este estudio presenta una perspectiva integral de la Industria 4.0 y el impacto de las nuevas tecnologías en las empresas modernas. El tercer capítulo se enfoca en los conceptos fundamentales de gestión de activos y los procesos utilizados de acuerdo con la tecnología vigente de la Industria 4.0. El cuarto capítulo revisa los conceptos matemáticos fundamentales necesarios para implementar metodologías analíticas predictivas como *Prognostic Health Maintenance* (PHM) predictiva y de pronóstico, la cual permite estudiar el comportamiento de los activos a partir de la salud de sus componentes. El capítulo cinco presenta una visión general del uso de las metodologías analíticas prescriptivas para optimizar las decisiones relacionadas con los componentes, los activos y la red de activos. Finalmente, para facilitar la comprensión, los anexos A, B y C presentan casos de uso, así como un guía de implementación de la metodología PHM en el sector eléctrico.

1.1 Optimización Integrada de la Empresa

Tradicionalmente, el modelamiento y la planificación se han realizado como si las áreas administrativas de las empresas trabajasen de forma separadas. Sin embargo, cada día es necesario integrar los modelos como uno solo para garantizar resultados óptimos para las empresas. La optimización integral o global de la empresa (EWO), es una dimensión de la integración empresarial que está relacionada con la evolución natural de los modelos de planificación que están vinculados a las funciones administrativas de la organización. EWO implica modelos matemáticos dinámicos que deben evolucionar de la misma manera que evoluciona la empresa.

La mayor integración, casi que obligatoria, se debe dar entre la producción, la energía y el mantenimiento, que hoy en día están íntimamente relacionados debido a su relación con la eficiencia energética en la industria intensiva y a la contaminación del medio ambiente (la gestión de la huella de carbono).

¹ Industria 4.0 es un término para referir a la cuarta revolución industrial y que se desarrolla en detalle en el Capítulo 2.

En las empresas que apuestan por la analítica avanzada como soporte para las decisiones, la modelización matemática se ha extendido a EWO para cubrir la visión holística cada vez más amplia y globalizada de la organización. Se ha pasado de una visión coordinada de las decisiones (i.e. un modelo alimentando a otro modelo) a la visión integrada con múltiples modelos ensamblados en un solo modelo integrado de alta complejidad. Esto lo permite la potencia de cálculo a la que actualmente tenemos acceso.

1.2 El Sector Eléctrico

1.2.1 Estructura

La energía es, en todas las regiones del mundo, una materia prima fundamental para el desarrollo de las actividades económicas y el bienestar de los hogares, pero también es una condición para alcanzar un desarrollo sostenible, que es un factor al que los inversores son cada vez más sensibles. La región requerirá una gran inversión en el sector eléctrico para cumplir con los planes de descarbonización (desafío de cero emisiones netas en 2050- Acuerdo de París) y abordar los desafíos como el aumento de la demanda, el acceso a la energía y el uso de fuentes más sostenibles. Las energías renovables solares y eólicas suponen un camino tecnológico para contribuir a alcanzar este objetivo, pero su contribución actual es baja y serán necesarias inversiones en infraestructura de redes de transmisión (BID, 2022).

En América Latina (LATAM), existen mercados eléctricos de naturaleza diversa y heterogénea, en concordancia con todo esto, hay perspectivas que son bastante positivas con muy buenos proyectos de expansión en marcha, a pesar de algunas dificultades macroeconómicas que enfrentan ciertos gobiernos. La digitalización está dando lugar a una transformación estructural cuya magnitud tiene pocos precedentes en América Latina y el Caribe y Los operadores del sistema de transmisión y distribución deben seguir facilitando la adopción de nuevos activos, como sistemas de gestión de recursos energéticos distribuidos, dispositivos de control, controles avanzados de voltaje y potencia reactiva, gemelos digitales de redes, inteligencia artificial y robots y drones para una gestión y operación más eficientes (IEA, 2022).

La segunda área donde la tecnología podría ofrecer grandes posibilidades es en el comercio de electricidad a través de las fronteras. América Latina tiene la estructura de transmisión de electricidad inter fronteriza más avanzada del mundo en desarrollo. No es comparable a la de Europa o los EE. UU. pero es mucho más importante que en otras regiones. Existen diversas conexiones regionales y binacionales en Sudamérica y Centroamérica: también entre países andinos, y en América Central. Sin embargo, esta infraestructura no está siendo utilizada adecuadamente. Los flujos de electricidad entre los países de cada una de las tres subregiones (Centroamérica, Sudamérica y Caribe) son mucho menores que lo que permite la infraestructura existente, y los precios a los que se realizan las ventas de electricidad están determinados por acuerdos políticos bilaterales, no en relación directa con el costo de generación de electricidad, o con las necesidades del país importador.

1.2.2 Reglamentación

La reglamentación aplicable a las actividades de generación, transporte, distribución y comercialización de energía es generalmente aprobada por una agencia reguladora de la energía, dependiente del Estado, quien desarrolla, en colaboración con los distintos agentes del sector

(generadores, grandes consumidores, gestores de distribución/transmisión), y sanciona los marcos de referencia legales en que cada uno de estos agentes pueden operar. A diferencia de la Unión Europea, en Latinoamérica aún no se ha avanzado mucho en la creación de un conjunto de normas comunes que permitan la integración cada vez mayor en un mercado común, por lo que aún es necesario hacer un análisis detallado del marco regulatorio de cada país para casi cualquier aspecto. En materia de mantenimiento de activos eléctricos, por lo general en la reglamentación se establecen los objetivos de calidad de suministro a conseguir y suele quedar como responsabilidad de la empresa dueña de los activos el adaptarse a los estándares de ingeniería pertinentes y optimizar sus decisiones de mantenimiento con base en sus compromisos de fiabilidad con sus clientes y su gestión financiera y de riesgo.

En este sentido, la propia regulación puede impulsar la transformación digital en sectores de energía regulados como por ejemplo estableciendo metas específicas de instalación de medidores inteligentes, subestaciones 100% controladas remotamente, entre otros.

1.2.3 Mantenimiento de Infraestructura Eléctrica

1.2.3.1 Generación

Las plantas de generación a media y gran escala tienen importantes costes asociados a sus mantenimientos, muy variables dependiendo de la tecnología del activo eléctrico. Por ejemplo, en el caso de energía renovables, los costes de mantenimiento (OPEX) en proyectos de media escala pueden suponer de 3.0 a 7.0% del CAPEX para plantas hidroeléctricas, de 4.4% a 6.0% del valor del CAPEX para eólica en suelo o de un 1.5% a 2.5% del CAPEX para solar en suelo (European Union, 2016). Una política de mantenimiento no optimizada reduce la eficiencia de los componentes (equipos) e incrementa la probabilidad y frecuencia de fallas y, por ende, la indisponibilidad (mayor duración de las paradas) resultando, en el mejor de los casos, en una drástica reducción de la rentabilidad de estas inversiones por excesivos costes asociados al mantenimiento y operación y, en el peor de los casos, a la inutilización permanente de costosísimos componentes (aerogeneradores, turbinas, transformadores de subestación, etc.) que puedan comprometer seriamente la viabilidad económica del proyecto. Como veremos a lo largo del estudio, el mantenimiento predictivo y prescriptivo, de la mano de las nuevas tecnologías, son fundamentales para implementar un mantenimiento inteligente que optimice la productividad de los activos.

La gran cantidad de datos en tiempo real o casi tiempo real que podemos medir, almacenar y analizar sobre decenas de parámetros de cada uno de los componentes de una instalación de generación, con un poder de computación al alcance de cualquiera, presenta una enorme oportunidad para monitorear con gran transparencia el estado de salud de los componentes y planificar los mantenimientos con base en criterios matemáticos de optimización y no simples reglas arbitrarias, generando un aumento de rentabilidad de las instalaciones por omisión de inspecciones, paradas o mantenimientos rutinarios innecesarios por un lado, o evitando fallos críticos que pueden pasar desapercibidos sin un análisis constante y automatizado de datos.

1.2.3.2 Transmisión

La transmisión de energía eléctrica en una determinada zona corresponde al monopolio natural de una sola compañía que recibe esta concesión del Organismo Regulador correspondiente en cada Estado. Corresponde a estas empresas la planificación, operación y el mantenimiento de toda la infraestructura eléctrica que hace posible el transporte de energía a alta tensión a través de largas distancias, cubriendo incluso fronteras entre distintos Estados. Dada la criticidad de los

activos como grandes líneas de alta tensión o subestaciones, estas empresas deben dedicar grandes recursos al monitoreo y mantenimiento del estado de salud de sus activos, pues pese a que los sistemas se operan casi siempre en condiciones que permiten el fallo simultáneo de uno o varios componentes, las consecuencias de fallos llegan a tener que activar costosas acciones de redespacho o incluso a tener que desatender demanda para evitar un colapso de la red. Todos estos costes evitables, con una planificación de mantenimiento más optimizada, se trasladan indirectamente de una forma u otra a los consumidores finales. Es por ello, que dado el enorme valor, dispersión geográfica y nivel de criticidad de los activos que conforman una red de transmisión, hacer el mejor uso posible del gran volumen de datos que podemos obtener en tiempo real para desarrollar modelos de mantenimiento predictivo optimizado, está en la agenda de todos los operadores de sistemas de transmisión.

1.2.3.3 Distribución y Redes Inteligentes (Smart Grids)

La distribución de electricidad corresponde a todas las redes que no son consideradas de transmisión o transporte por tener una tensión inferior a un umbral (distinto según el país), que transportan la energía desde las subestaciones de transporte hasta los consumidores finales. Con la aparición, en décadas anteriores, de contadores inteligentes para medir el consumo en tiempo casi real (Smart meters), y otros muchos sensores asociados al estado de los distintos transformadores, circuitos, interruptores, etc. que conforman la red, se presentan innumerables oportunidades de aumentar la eficiencia en el mantenimiento y mejorar la calidad del suministro reduciendo interrupciones en éste, que antes, ante la falta de esta información en tiempo real y el conocimiento para procesarla, eran derivadas de investigaciones manuales de los fallos, mantenimientos rutinarios evitables, no-detección de anomalías como conexiones ilegales etc. Hoy en día, las principales distribuidoras prestan gran atención a incorporar las arquitecturas de datos y algoritmos de procesamiento que mayor eficiencia puedan aportar al mantenimiento de sus activos.

1.3 Modelamiento del Mantenimiento de la Infraestructura Eléctrica

1.3.1 Marco de Referencia

Para abordar el problema de mantenimiento de infraestructura en la industria intensiva eléctrica es conveniente abordar el problema de los Activos, que están relacionados con el tamaño de la infraestructura, y se pueden agrupar como:

- Componentes (partes, máquinas, generadores, transformadores, líneas de distribución, etc.), que son los átomos, o moléculas, de la infraestructura productiva y que es donde se producen las fallas. En un modelaje “bottom-up” es el elemento más elemental del sistema (como se describe en sección 3.3.4).
- Redes de Activos (sistemas). Los sistemas de ingeniería complejos resultan de la integración de redes de múltiples componentes individuales, que funcionan de forma interactiva, y que cuando fallan a nivel individual pueden influir muy seriamente en el rendimiento del sistema como un todo. Por lo tanto, el desarrollo de metodologías para el monitoreo y control a nivel de sistema también es importante, tanto como las metodologías a nivel de componente. En general el pronóstico de la “salud” de los activos se basa en la integración matemática de la de la “salud” a nivel de componente, que es la que se mide directamente.

Las redes de componentes pueden concebirse de acuerdo con una jerarquía en la que una red de componentes de mayor nivel está compuesta por redes de componentes de menor nivel, que a su vez pueden estar compuestas por otras redes de componentes y así sucesivamente.

Para una apropiada integración, se debe tener un marco de referencia estandarizado para organizar la infraestructura de la empresa eléctrica. La Norma ISA-95, desarrollada por la Sociedad Internacional de Automatización, y posteriormente actualizada con Industria 4.0, define un modelo abstracto de empresa, incluyendo las funciones de control de fabricación y funciones comerciales, y su intercambio de información. Promueve la integración entre los departamentos y el mejoramiento de los flujos de información en las empresas.

1.3.2 Analíticas Avanzadas: Predictiva y Prescriptiva (Optimización)

La optimización de la planificación del mantenimiento de la infraestructura eléctrica es un problema cotidiano en todos los sectores productivos, ya que implica la coordinación de las actividades productivas (que utilizan como recurso principal dicha infraestructura eléctrica), con las actividades de mantenimiento que se requieren para que la infraestructura trabaje eficazmente.

La visión moderna de la optimización de la infraestructura eléctrica implica el uso de las metodologías y de las tecnologías relacionadas con la analítica avanzada. Para asignar las actividades de mantenimiento y las actividades productivas se utilizan dos tipos de analítica:

- Predictiva (“forecasting”), modelos orientados a determinar las condiciones de funcionamiento de los equipos, se utilizan modelos que determinan las distribuciones de probabilidad de:
 - Falla de cada equipo, y
 - La vida útil remanente hasta la próxima falla.

Se utilizan modelos basados en Inteligencia Artificial, “Machine Learning” y Modelamiento Probabilístico Avanzado.

- Prescriptiva (optimización), modelos orientados a determinar las decisiones óptimas, basados en programación matemática (que se resuelven utilizando «solvers» de alto rendimiento, descrito en detalle en Anexo A.3.5) y/o en metaheurísticas (que se resuelven con programas especializados y asociados al problema específico Ref. 5.2.3);

2 Industria 4.0 (I4.0)

Este capítulo tiene como objetivo presentar una visión integral de la revolución que supone la Industria 4.0 (Cuarta Revolución Industrial) con la finalidad de que el lector comprenda el impacto de las nuevas tecnologías en las empresas modernas y principalmente en aquellas que enfrentan procesos intensivos de transformación digital, como es el caso de las empresas del sector eléctrico.

Industria 4.0 (I4.0) es un nombre dado a la tendencia actual de automatización e intercambio de datos en tecnologías de fabricación. Incluye sistemas ciberfísicos (Cyber-Physical Systems o CPS), IoT (Internet of Things e Internet of Industrial Things), computación en la nube (Cloud Computing) y computación cognitiva, concepto que fue acuñado por Klaus Schwab en 2016. Hoy en día, I4.0 se conoce comúnmente como la Cuarta Revolución Industrial vinculada a la fabricación inteligente (Smart Manufacturing) basada en un nuevo factor productivo: la información, y dando origen a la economía de conocimiento intensiva.

Las nuevas tecnologías juegan un papel fundamental en el proceso de digitalización de procesos hasta ahora inalcanzables, presentando infinidad de aplicaciones en el sector energético como la implementación del mantenimiento inteligente predictivo y prescriptivo (tema central de este estudio), optimización del ajuste de oferta y demanda, mejora de la relación e interfaz con el cliente final, desarrollo de nuevos servicios, etc.

2.1 Sistemas Ciberfísicos (CPS)

I4.0 es la tendencia actual en la automatización e intercambio de datos, particularmente en el marco de las tecnologías de fabricación y desarrollo tecnológico. Los CPS monitorean los procesos físicos, crean una copia virtual del mundo físico y toman decisiones descentralizadas. Un CPS es un mecanismo (un sistema físico) controlado o monitoreado por algoritmos basados en computadora (una inteligencia artificial) y estrechamente integrado con Internet (un sistema cibernético).

Ejemplos de CPS incluyen sistemas de redes eléctricas inteligentes (smart grids). Gracias a IoT, los CPS se comunican y cooperan entre sí y con los humanos en tiempo real, tanto internamente como a través de los servicios organizacionales ofrecidos y utilizados por los participantes de la cadena de valor. Sin embargo, la participación del humano es cada vez menor debido a la evolución tecnológica que permite a las máquinas resolver, sin errores, problemas técnicos cada vez mayores. CPS implica un enfoque multidisciplinario, fusionando la teoría de la cibernética, la mecatrónica, el diseño y la ciencia de procesos, con la matemática como soporte del conocimiento de la humanidad.

I4.0 se caracteriza por la fusión de tecnologías actuales y en prueba (o en desarrollo), que está desintegrando los límites entre las esferas física, digital, biológica y neurocientífica; luego, está marcado por los avances tecnológicos emergentes en una serie de campos, que incluyen robótica, inteligencia artificial, aprendizaje automático, blockchain, nanotecnología, computación en la nube, computación cuántica, biotecnología, IoT, impresión 3D, analítica avanzada (predictiva y prescriptiva) y vehículos autónomos. Paradójicamente, no se hace mucha referencia al modelado algebraico formal (Programación Matemática) que soporta todas las áreas del conocimiento, incluyendo el comportamiento de las personas y de las organizaciones sociales.

2.2 IoT, Big-Data y Smart Metering

En analítica avanzada (predicción y optimización) lo convencional fue pensar que un problema se resuelve en un momento dado y vuelve a resolverse periódicamente (cada hora, día, quincena, etc.), esto presupone que la información que se requiere para ejecutar el modelo analítico se logra de una ejecución a la siguiente. El Big Data generado por los sistemas de medición inteligente (recopilación continua de datos) cambia por completo el entorno de toma de decisiones permitiendo reaccionar a los eventos con toma de decisiones en tiempo-real. Esto es posible gracias al mayor poder computacional de los equipos y a la computación distribuida, computación paralela o computación en el borde (edge computing).

IoT (Internet de las Cosas o Internet of Things) tiene un impacto positivo en el mantenimiento predictivo dado que permite una vigilancia amplia de los equipos y de los procesos (permanente y en forma remota), a un costo mucho más bajo que los métodos tradicionales, y proporciona advertencias accionables en tiempo-real, para prevenir o reducir al mínimo las consecuencias de fallas.

Los nuevos sistemas integrados software-hardware que realizan los procesos de analítica predictiva (PHM o Prognostic Health Management predictivo) cada vez más se basan en “sensores inteligentes” que integran las labores de diagnóstico y de predicción como parte del hardware y que tiene relación directa con edge computing. Los sistemas de medición inteligentes (Smart Metering) permiten el uso del software para resolver problemas industriales (eléctricos), ya que hoy está disponible, en tiempo-real y remotamente, una cantidad de datos (big-data) antes impensada.

2.3 Digitalización en integración de las cadenas de valor en el sector eléctrico

Las tecnologías inteligentes emergentes durante la I4.0 en energía eléctrica son:

Distritos de Energía Inteligentes

En la última década, el interés por la generación distribuida (GD) se ha introducido drásticamente debido a las innovaciones tecnológicas y a un entorno económico y regulatorio cambiante. Las pequeñas plantas privadas, especialmente de fuentes de energía renovable (difícilmente despachables centralmente), están conectadas directamente a la red. La inteligencia se inyecta en la gestión de un distrito energético para mejorar la eficiencia energética global en forma de soluciones IoT que tienen como objetivo el intercambio de energía dentro de las diversas plantas de generación distribuida y el sistema local de almacenamiento de energía con la red de distribución, de forma tal de mejorar la eficiencia energética y reducir los costos. El procedimiento de predicción y generación de energía georreferenciada utiliza el Sistema de Información Geográfica (SIG) para localizar a los consumidores y en función de sus categorías (es decir, oficinas residenciales, industriales o corporativas) determinar la operación óptima.

Redes Inteligentes

Las tecnologías de redes inteligentes (Smart Grids, SG) surgieron como consecuencia del desarrollo del control electrónico, la medición y el monitoreo. La red inteligente establece una interacción bidireccional entre el consumidor y la empresa de servicios públicos donde se puede intercambiar la electricidad y la información. SG es una red de comunicación, controles,

computadoras, automatización y nuevas tecnologías y herramientas que trabajan conjuntamente para hacer que la red sea más eficiente, más confiable, más segura, lo que también mejora la velocidad de detección de fallas y permite, sin intervención humana, la auto reparación de la red mediante un posible cambio de ruta y/o cambio a otra fuente, o activo, saludable. Esto también mejora la confiabilidad del suministro eléctrico y reduce la vulnerabilidad a desastres naturales o ataques. SG puede verse como la última actualización de los sistemas de energía eléctrica preexistentes, que permite las puertas de enlace (gateways) dinámicas para la generación y el almacenamiento distribuidos, y la optimización inteligente del uso de la energía que se cobra automáticamente en función de su consumo. Las SGs deben incluir las características básicas como la tolerancia a fallos (al resistir ataques), la capacidad de auto reparación, la optimización dinámica, la confiabilidad mejorada, la calidad de la energía, la incorporación de la respuesta a la demanda y la integración de fuentes de energía distribuidas. La Academia Nacional de Ingeniería en los Estados Unidos (USA National Academy of Engineering) define las SGs como uno de los principales logros de la humanidad en el siglo XX (Venayagamoorthy, 2011).

Medidores de Energía Inteligentes

Smart Metering (infraestructura de medición avanzada o medidores inteligentes) permite la comunicación bidireccional entre el proveedor y el consumidor, para garantizar el suministro de energía confiable al i) minimizar la interrupción y las pérdidas y ii) optimizar los costos de energía, mediante la instalación de monitoreo y control remoto. Los medidores de energía inteligentes se utilizan para registrar el consumo de energía cada hora, o con más frecuencia, e informan al menos diariamente al proveedor de servicios públicos. La infraestructura de medición inteligente también desempeña un papel vital en otras aplicaciones, como la detección del robo de electricidad, la mejora de la seguridad del sistema, el despacho y control de la carga, junto con el desarrollo de regiones inteligentes y el mantenimiento preventivo basado en analítica avanzada.

Automatización del Sistema de Distribución

Para el control flexible de los sistemas de distribución, la automatización del sistema (Distribution System Automation, DSA) desempeña un papel vital que puede mejorar la eficiencia, la confiabilidad y la calidad del suministro eléctrico. DSA ha sido definido por IEEE como sistemas que permiten a una empresa eléctrica monitorear, coordinar y operar componentes de distribución en tiempo-real desde ubicaciones remotas. Para hacer que DSA sea más inteligente, eficiente y rentable, la investigación y el desarrollo se centran en las áreas de las tecnologías de comunicación, el modelamiento matemático avanzado y la aplicación de protocolos estandarizados. DSA se establece no solo como operación y control remotos de subestaciones y alimentadores, sino que se está transformando en un sistema de energía autorreparable que responde de inmediato a las acciones apropiadas en tiempo real, la previsión inteligente de la carga y la gestión de la demanda. Diferentes autoridades eléctricas también han presentado el plan para preparar un inventario basado en el Sistema de Información Geográfica (SIG) para rastrear sus postes, transformadores, cables, conexiones de los consumidores a cada transformador para conocer todos los datos, sus existencias y su salud en el sistema de distribución.

2.4 Digitalización de Productos y Servicios

2.4.1 Gemelos Digitales

Un gemelo digital (Digital Twin, DT) es una representación virtual que sirve como la contraparte digital en tiempo real de un objeto o proceso físico. El concepto es atribuido a Michael Grieves en el año de 2002 en la Universidad de Michigan (Grieves, 2016); Los gemelos digitales fueron anticipados por David Gelernter en el libro de Mirror Worlds (Gelernter, 1991). La primera definición práctica de un gemelo digital se originó en la NASA en 2010 para mejorar la simulación del modelo físico de las naves espaciales (Shafro et al., 2010). Los gemelos digitales son el resultado de la mejora continua en la creación de actividades de diseño e ingeniería de productos. Los dibujos de productos y las especificaciones de ingeniería han progresado desde el dibujo hecho a mano hasta el dibujo y el diseño asistido por computadora y la ingeniería de sistemas basada en modelos, la cual data de muchas décadas, cuando se crearon los modelos de diferencias y de elementos finitos de los sistemas y procesos físicos.

El concepto de gemelo digital consta de tres partes: i) el producto físico, ii) el producto virtual y iii) las conexiones entre los dos productos. Las conexiones entre el producto físico y el producto digital son datos que fluyen del producto físico al virtual e información que está disponible desde el producto virtual al entorno físico. La simulación de los gemelos digitales captura cómo el equipo opera, cómo los ingenieros lo mantienen, o incluso cómo los bienes que el equipo fabrica se relacionan con los clientes.

El modelado de DT puede irse perfeccionando y optimizando de forma continua con base en las mediciones en tiempo real del producto físico. Los gemelos digitales permiten simular diversos escenarios de funcionamiento del producto físico real (de forma virtual, sin necesidad de hacer experimentos en el producto físico), lo que permite hacer análisis de riesgo, eficiencia, etc. especialmente útil para sistemas de generación.

Con los avances tecnológicos, actualmente los gemelos digitales pueden simular aspectos de componentes de la infraestructura eléctrica (por ejemplo, turbinas de un aerogenerador, transformador de alta tensión); a partir de los planos pueden representar las dimensiones de ingeniería de un producto nuevo, o representar todos los subcomponentes y la correspondiente cadena de abastecimiento extendida desde la mesa de diseño hasta el consumidor con base en el gemelo digital de “como está construido el producto final. También pueden tomar la forma de “como está mantenido” o una representación física de equipo en el piso de producción.

Hoy en día, los DT son parte de las soluciones de tiempo-real ya que interactúan como: i) supervisores y ii) generadores de datos de las soluciones de analítica predictiva (“forecasting”) y de analítica prescriptiva (optimización).

2.4.2 Realidad Virtual y Realidad Aumentada

La Realidad Virtual (Virtual Reality, VR) y la Realidad Aumentada (Augmented Reality, AR) son herramientas que ofrecen posibilidades para facilitar las tareas de mantenimiento de activos eléctricos.

La VR es un entorno completamente simulado al que el usuario accede mediante una interfaz que incluye al menos un auricular y algún tipo de control para interactuar. En contraparte, la AR requiere de la existencia de un contexto real sobre el que se implementan los elementos simulados.

Realidad Virtual

La VR recrea un espacio tridimensional virtual inmersivo, similar a uno real. Al usar unas gafas de realidad virtual, el usuario está totalmente privado de la visión real que tiene a su alrededor, lo que permite sumergirse en el escenario virtual recreado. El usuario puede interactuar dentro de ese mundo virtual mediante guantes o mandos, que le permiten agarrar y lanzar objetos, abrir puertas, etc. Este aislamiento del entorno real e inmersión en el entorno virtual, combinado con el proceso interactivo del usuario, permite realizar simulaciones de la realidad en las que la persona tiene una sensación de presencia real. Esta técnica, permite un aprendizaje mental y locomotriz mucho más eficiente que en un curso convencional con videos y manuales.

La VR se puede utilizar para entrenamiento de actividades de mantenimiento (por ejemplo trabajo en líneas aéreas, reparación de turbinas eólicas, maniobra de celdas de alta tensión) o simular maniobras de operación arriesgadas recreando espacios, entornos y situaciones virtuales interactivas con el fin de que una vez pasado el aprendizaje, el usuario sepa lo que tenga que hacer y lo haga de forma automática una vez enfrentado a la situación real.

Realidad Aumentada

La AR es una capa de elementos virtuales superpuestos sobre el mundo real, que solo requieren un dispositivo como un teléfono móvil, o una Tabla para interaccionar. La tendencia es que los fabricantes de componentes implementen funcionalidades de realidad aumentada para facilitar las labores de inspección y mantenimiento del equipo físico.

2.5 Marco de Referencia Analítico

2.5.1 Analítica Avanzada y Robots Cognitivos

Los robots cognitivos (Cognitive Robots, CR) son fundamentales en la Industria 4.0; se basan en conceptos de la Inteligencia Artificial (IA) y escriben los algoritmos de analítica avanzada que se requieren para la transformación digital de las organizaciones, vinculándolos automáticamente al sistema de información empresarial. Un CR es un robot experto que crea robots en forma de algoritmos para procesos complejos, utilizando metodologías matemáticas avanzadas de última generación. Este proceso de robotización se encuentra en el nivel más alto de automatización, porque no reemplaza el trabajo humano manual, sino que apoya la construcción de robots que reemplazan tareas cognitivas humanas, relacionadas con: i) el modelado matemático (predicción y optimización) de procesos estocásticos y/o procesos comerciales/industriales, y ii) el procesamiento de los resultados de múltiples (cientos o miles, pueden ser millones) modelos de optimización.

Un CR aumenta la productividad del modelador matemático; entendiendo la productividad como: más modelos en menos tiempo, y asegurando la calidad de los algoritmos producidos. Para desarrollar los CRs es necesario el modelado matemático estructurado, esto hace que los CRs sean independientes de las tecnologías matemáticas industriales. Así como en el trabajo manual los robots potencian la capacidad humana, en el proceso cognitivo los robots promueven el conocimiento, sistematizan las tareas cognitivas que son repetitivas, como: i) escribir programas, ii) comprobar datos de sistemas de información de datos industriales, iii) analítica de datos, iv) comprobar la formulación matemática almacenada en sistemas de información de modelado matemático, ..., todo esto libre de errores. Un CR acelera los tiempos de desarrollo; permite hacer

un modelo que funciona correctamente en minutos, u horas, lo que implica llevar el conocimiento producido a los procesos en “tiempo-real”.

2.5.2 Transformación Digital: Mantenimiento de Activos Eléctricos en I4.0

El Pronóstico y Gestión de la Salud de los activos (Prognostics and Health Management o PHM) es un término que se refiere a la utilización de sensores, sistemas de monitoreo y control para detectar, evaluar y rastrear la degradación del estado del sistema y los modos de falla para permitir una mejor administración y decisiones operativas. PHM se origina con la idea de que se puede determinar la "salud" (o degradación) de los activos y predecir la confiabilidad (y la vida útil, y/o el rendimiento útil restante durante la vida útil del activo) con la ayuda de la detección en campo.

Los enfoques interdisciplinarios de pronóstico y de gestión de la salud de los activos, como PHM, utilizan los datos y las nuevas tecnologías (IoT, Big Data, etc.) y se ocupan del monitoreo del estado del sistema, la detección de fallas, el diagnóstico de la causa de las fallas y el pronóstico de las fallas a nivel de componentes y sistemas, mediante el uso de métricas como la Vida Útil Restante (RUL, Remaining Useful Life). Las tecnologías PHM se están incorporando ampliamente a la infraestructura eléctrica a medida que es posible una evaluación del sistema en tiempo real (por ejemplo, componentes esenciales en nodos de redes de distribución y transmisión eléctrica como transformadores o equipamiento de conmutación)

Un informe reciente de McKinsey & Company, encontró que la implementación de sistemas PHM pueden aumentar la disponibilidad de activos entre el 5% y el 15% y reducir los costos de mantenimiento entre el 18% y el 25% (McKinsey & Company, 2018).

Estos enfoques benefician en gran medida las operaciones de mantenimiento al reducir el tiempo de inactividad y por ende los costos. Una de las razones de estos costos relativamente altos es que las empresas prefieren el mantenimiento correctivo² y/o el preventivo³, en lugar del mantenimiento predictivo⁴ y/o prescriptivo⁵.

2.5.3 Inteligencia artificial (IA) y toma de decisiones en I4.0

El concepto de uso de las nuevas tecnologías (IA, IoT, Big Data) al servicio de las analíticas avanzadas para la toma de decisiones inteligente en el mantenimiento de la infraestructura eléctrica tiene infinidad de aplicaciones en otros ámbitos de la organización.

-
- 2 El mantenimiento correctivo consiste, básicamente, en que si algún equipo falla, se procede a su reparación lo antes posible. No ofrece visibilidad.
 - 3 En el mantenimiento preventivo se realizan acciones periódicamente sobre los equipos sin tener en cuenta el estado de salud los mismos (por ejemplo, no se analiza signos de desgaste o de un posible fallo inminente).
 - 4 El mantenimiento predictivo es un mantenimiento inteligente y avanzado que requiere contar con tecnologías avanzadas de análisis de datos como la inteligencia artificial y algoritmos de Machine Learning y Big Data para la monitorización en tiempo real de las variables claves de cada equipo y definir la intervención cuando sus valores están cerca o fuera de sus límites de seguridad.
 - 5 Conociendo el pronóstico y salud de los componentes estimado por la analítica avanzada predictiva, el mantenimiento prescriptivo resuelve analítica avanzada de optimización y nos aconseja cuando intervenir en función de las condiciones de contorno y recursos disponibles, optimizando el impacto a nivel holístico.

PHM es una de las aplicaciones más efectivas de la inteligencia artificial en el sector eléctrico. La inteligencia artificial es, por tanto, la tecnología que posibilita este servicio. La aplicación de inteligencia artificial para el desarrollo de modelos PHM representa en general un gran valor añadido. En el caso de que el conocimiento del comportamiento del sistema sea limitado, esta aplicación es particularmente eficaz, ya que permite tener en cuenta la historia de la degradación del componente relativo y, en consecuencia, obtener predicciones más refinadas sobre la RUL del componente

Por ejemplo, la IA puede mejorar las proyecciones de generación y demanda de electricidad, lo que resulta en una mejor toma de decisiones de producción. Esto es crucial en el sector de las energías renovables porque estas fuentes fluctúan con frecuencia debido al clima, el viento o los flujos de agua, y dependen de los combustibles fósiles para su respaldo. La dependencia de estos sistemas de respaldo puede reducirse o eliminarse, si la infraestructura de almacenamiento de energía está integrada con analíticas prescriptivas basadas en IA.

A medida que crezca la generación distribuida, los usuarios ahora participarán activamente en la producción de electricidad (productores o consumidores según la ventana de tiempo; también llamados prosumidores). La AI simplificará la elección de los mejores momentos para que la generación distribuida contribuya a la red en lugar de aprovecharla a medida que estos prosumidores (por ejemplo, energía solar en tejado) crezcan en importancia dentro del sistema. El auge de las energías renovables intermitentes, la generación distribuida, incluidos los prosumidores, y las nuevas tendencias del lado de la demanda, como el auge de los vehículos eléctricos, pueden ser equilibrados por los productores tradicionales y los operadores del sistema con la ayuda de la IA.

3 Teoría de Gestión de Activos

El objetivo de este capítulo es presentar los conceptos fundamentales de la gestión de activos, (descrita como la integración de actividades de operación y mantenimiento), la importancia de la idea de gestión holística y de los procesos metodológicos a seguir para su realización de acuerdo con las nuevas tecnologías vigentes en la Industria 4.0.

3.1 Mantenimiento de Infraestructura Eléctrica

3.1.1 Marco de Referencia y Conceptualización

El uso de soluciones PHM para mejorar la fiabilidad y la disponibilidad efectivas de un activo a lo largo de su ciclo de vida se está volviendo gradualmente más importante, y el proceso PHM es ahora crítico en la I4.0 o industria inteligente.

La confiabilidad, la disponibilidad, la mantenibilidad y la seguridad actualmente se aplican ampliamente como resultado del mantenimiento que ofrece I4.0, dando lugar a los sistemas de mantenimiento inteligente (SMI) en los que la detección y el diagnóstico de fallos son críticos ya que ayudan a mejorar la disponibilidad, la productividad y la seguridad de las personas, y de los equipos, al detectar problemas tempranamente. Las nuevas tecnologías de la industria están afectando gradualmente a las formas tradicionales de controlar el estado de la salud de los equipos, como el clásico mantenimiento preventivo y correctivo.

Previo a la presentación de la teoría de Gestión de Activos cabe definir los siguientes conceptos:

- **Activo:** Unidad básica que puede realizar una actividad dentro de la industria eléctrica. Está compuesto por múltiples componentes. Ejemplo: Una turbina de generación, un transformador, un inversor solar o una celda de media tensión.
- **Componente:** Unidad básica que componen los activos. Cada componente puede fallar individualmente y estar relacionado con otros componentes. Ejemplo, el IGBT de un inversor solar, el interruptor de una celda de protección en una subestación de media tensión, etc.
- **Red de Activos:** Conectividad de los activos dentro de un sistema o un subsistema. Su actividad debe planificarse conjuntamente. Por ejemplo, un conjunto de unidades de generación en una central de generación de energía, conjunto de redes eléctricas de distribución conectadas a un nodo de la red de transmisión, etc.
- **Sistema:** Conjunto de activos que trabajando coordinadamente se utilizan para lograr los objetivos de la organización. Ejemplo: una central de generación de energía, una planta fotovoltaica o una subestación.
- **Subsistema:** Divisiones del sistema en grupos de activos de acuerdo con su similitud o con su actividad conjunta. Por ejemplo, conjunto de inversores solares o transformadores, flota de drones utilizados para la inspección de líneas aéreas, etc., que forman parte de un sistema productivo mayor.

3.1.2 Teoría de Gestión de Activos

La desregulación del mercado de la energía ha llevado, en los países industrializados, a un creciente interés en la optimización del sistema de energía y a centrarse a optimizar las demandas de los clientes. La minimización de los costes de operación y mantenimiento mediante la implementación y automatización de analíticas avanzadas (predictivas y prescriptivas) son implicaciones esenciales para la futura política de gestión de activos eléctricos.

Para este escenario se debe desarrollar un sistema integral de apoyo a la decisión para la gestión de activos de infraestructuras eléctricas, que proporcione apoyo en la elaboración de perfiles de las demandas de los propietarios de activos y en la evaluación del estado técnico, económico y social de los activos.

La gestión de activos por tanto se puede abordar desde los siguientes enfoques:

- El primero consiste en información técnica de activos y evaluación de condición, y se centra en los componentes,
- El segundo nivel combina la información económica sobre activos con los resultados del primer nivel y tiene más enfoque en el nivel de confiabilidad de la red,
- El tercero utiliza la información económica sobre los negocios, combinada con la información social, para tomar decisiones sobre el riesgo que tiene un enfoque corporativo.

Equilibrar el costo y los beneficios de los escenarios con el riesgo involucrado con cada escenario dará como resultado la decisión final con el riesgo mejor gestionado. La información social y económica, junto con la fiabilidad del inventario de equipos y la topología de la red forman los ingredientes de los riesgos implicados.

Los participantes en el proceso de gestión de activos y sus roles se presentan en la siguiente tabla.


Tabla 1: gestión de activos: Participantes y roles

Rol	Responsabilidad
Propietarios	Maximizar la rentabilidad de la empresa. Garantizar la estabilidad del sistema productivo.
Operadores	Programación de actividades de mantenimiento. Mantenimiento oportuno. Tiempo de actividad del sistema. Minimizar mantenimiento innecesario.
Logísticos	Disponibilidad de repuestos. Recuento reducido de repuestos. Huella logística.
Gerente de Producción / Servicios	Satisfacer las expectativas de los clientes.
Gerente de Activos	Salud de la flota/red de activos. Costo del ciclo de vida. Capacidad de la misión de mantenimiento. Planificación de la misión de mantenimiento. Minimizar el tiempo de inactividad.
Organismos Reguladores	Seguridad. Evitar fallas catastróficas. Minimizar el impacto negativo en otros sistemas.
Ingenieros	Satisfacción de los requisitos. Robustez. Diseño de políticas de mantenimiento.

3.2 Ingeniería de Confiabilidad

La confiabilidad está estrechamente relacionada con la disponibilidad, que generalmente se describe como la capacidad del activo para funcionar en un momento, o intervalo de tiempo, específico. La Ingeniería de Confiabilidad es una subdisciplina de la ingeniería que estima la capacidad de los equipos físicos (un sistema y/o una componente) para funcionar en las condiciones establecidas durante un período específico.

Figura 1: Ejemplo de curva probabilística de fallas tipo bañera



Fuente: Cataño (2014)

La ingeniería de confiabilidad se ocupa de la predicción, prevención y gestión “de por vida” de altos niveles de incertidumbre y riesgos de falla. Las tecnologías modernas basadas en modelos matemáticos avanzados conllevan a que el estado-del-arte de la ingeniería de confiabilidad está basada en métodos cuantitativos.

La economía de la ingeniería de confiabilidad se centra en los costos de las actividades de mantenimiento, los cuales corresponden a la suma de los costos directos e indirectos de fallas causadas por: i) el tiempo de inactividad del sistema, ii) el costo de los repuestos, la reparación del activo, el costo del personal, el costo de las reclamaciones de garantía, las penalizaciones legales, el lucro cesante, etc.

3.3 Tipos y Decisiones de Mantenimiento

La confiabilidad de la infraestructura eléctrica y energética es uno de los principales problemas en la actualidad, por lo que el desarrollo de técnicas avanzadas de mantenimiento del sistema integral y de sus componentes individualmente es una tarea transcendental.

El proceso de gestión del mantenimiento inteligente de activos integra dos tipos de analítica:

- Predictiva: metodologías y tecnologías orientadas a realizar predicciones sobre las variables;
- Prescriptiva: metodologías y tecnologías orientadas a determinar el valor óptimo de las variables de control.

El Capítulo 4 se concentra en la aplicación de la analítica predictiva y el Capítulo 5 en la analítica prescriptiva. El Anexo C se incluyen referencias a literatura donde se profundiza en los aspectos metodológicos de los dos tipos de analítica.

3.3.1 Prácticas de Mantenimiento

Las técnicas de mantenimiento se pueden agrupar en dos categorías extremas:

- Mantenimiento correctivo, consiste en reemplazar el componente y reparar el daño después de alguna falla importante. Si los costos de falla son muy altos, definitivamente esta estrategia no puede ser la óptima. Este es un estándar tradicional de mantenimiento no valido en mantenimiento inteligente.
- Mantenimiento anticipado, se refiere a evitar el problema mediante el reemplazo oportuno de la fuente de la falla, ocupándose de la falla antes de que suceda. El mantenimiento anticipado se puede dividir en dos:
 - Basado en el tiempo (Time-Based Predictive Maintenance, TBM); lo que significa que los componentes se reemplazan en función de un programa predefinido que se basa en las horas de trabajo (u otra medida de consumo de vida útil) del componente. Obviamente, este enfoque no es óptimo, ya que los componentes se reemplazan antes del final de su vida útil, lo que aumenta los costos debido a recursos no-utilizados. Asimismo, este mantenimiento también está sujeto a que algunos componentes presenten fallas antes de la vida útil esperada, ocasionando problemas adicionales. El TBM se corresponde con el tradicional mantenimiento preventivo donde se realizan acciones periódicamente sobre los equipos sin tener en cuenta el estado de salud los mismos (por ejemplo, no se analizan signos de desgaste o de un posible fallo inminente). Tampoco es válido en mantenimiento inteligente.
 - Basado en la condición (Condition-Based Predictive Maintenance, CBM), que utiliza el diagnóstico de fallas, detección de comportamientos anormales en el sistema, así como la revelación de sus causas y ubicaciones. El pronóstico proyecta la evolución de fallas del componente a lo largo del tiempo y estima:
 - La vida útil restante (RUL, Remaining Useful Life) y
 - El final de la vida útil (EOL)


El mantenimiento CBM se corresponde con el mantenimiento predictivo, fundamental, junto con el mantenimiento prescriptivo (optimización), en mantenimiento inteligente de activos.

3.3.2 Mantenimiento Basado en la Condición (CBM)

El mantenimiento basado en la condición de los equipos representa la evolución de la práctica de ingeniería reactiva a proactiva, habiendo superado a través del tiempo las siguientes etapas:

- a) Reparar o reemplazar cuando esté roto;
- b) Mantenimiento centrado en la fiabilidad: Enfoque sistemático para garantizar que los activos continúen haciendo lo que sus usuarios requieren en el contexto operativo actual;
- c) Diagnóstico mejorado: proceso soportado en por qué un componente ha fallado;
- d) Mantenimiento basado en la condición (CBM): predecir el estado futuro de un componente para que el mantenimiento se realice en función de la condición real del componente.

Figura 2: Costos de implementación y beneficios en metodologías de mantenimiento



Fuente: Taheri et al. (2019)

3.3.3 Mantenimiento Pronóstico de la Salud (PHM)

Los sistemas PHM son uno de los principales protagonistas de la revolución I4.0. Detectar de manera eficiente si un componente se ha desviado de su condición normal de funcionamiento, o predecir cuándo ocurrirá una falla, son los principales desafíos que el PHM aborda disminuyendo la probabilidad de eventos de falla, mejorando el nivel de seguridad de los activos y sus componentes. El PHM está directamente vinculado con el CBM y se puede afirmar que es la metodología práctica vigente para implementar CBM considerando la I4.0. Adicionalmente, el PHM reduce drásticamente los costos (visibles e invisibles). Los beneficios del PHM están resumidos en la siguiente tabla:

Tabla 2: Beneficios del mantenimiento PHM

Actividad	Beneficio
Costo del ciclo de vida	Menores costos operativos. Aumento de los ingresos.
Diseño e implementación	Optimización del diseño del sistema. Predicción de fiabilidad mejorada. Mejora del sistema de apoyo logístico.
Producción	Mejor control de calidad del proceso. Mayor eficiencia y eficacia de los procesos. Desarrollo de mantenimiento integrado por OEMs.
Operación del sistema	Refuerzo de la seguridad del sistema. Mayor fiabilidad operativa. Mayor eficiencia y eficacia de la operación del sistema.

Actividad	Beneficio
Soporte logístico	Mantenimiento basado en la condición. Soporte de decisiones mejorado en toda la flota. Cadena de suministro logística optimizada. Disminución de fallas inducidas.

Los beneficios (resumidos en la tabla anterior) económicos del uso del PHM se pueden estimar en un 18-25% y se derivan tanto de un mayor beneficio como de una reducción de costes. El PHM, de hecho, garantiza, por un lado, un menor tiempo de inactividad promedio del sistema y, por otro, menores costos de mantenimiento, que de hecho se optimizan al estar dirigido a los elementos en estado de falla y no extenderse a todo el sistema o la red.

Algunos de los casos propuestos por McKinsey en sus informes ayudan a justificar estas cifras. Un ejemplo clave es el caso de Vistra Power. Vistra Corp. es el productor de energía competitivo más grande de los Estados Unidos y opera plantas de energía en 12 estados con una capacidad de más de 39,000 megavatios de electricidad, suficiente para abastecer a casi 20 millones de hogares. El operador de energía que adoptó un modelo de red neuronal multicapa para las unidades de generación de energía en 26 plantas, para una mejora promedio del uno por ciento en la eficiencia y más de \$23 millones en ahorros. Junto con las otras iniciativas de IA, estos esfuerzos han ayudado a Vistra a reducir alrededor de 1.6 millones de toneladas de carbono por año, lo que representa el 10% de su compromiso restante de reducción de carbono para 2030 (McKinsey & Company, 2018).


El Anexo B de este documento presenta más detalles sobre la implementación de sistemas PHM.

3.3.4 Modelamiento de los Activos en sistemas PHM

La implementación del PHM implica descomponer el sistema/subsistema en componentes fundamentales cuya unión representa el activo total. El enfoque de modelaje es del tipo “bottom-up” en el que a partir de las componentes se explica el funcionamiento del activo como un todo. La siguiente figura presenta como ejemplo la descomposición de un generador eólico en sus componentes principales, los que pueden ser componentes elementales indivisibles o subsistemas autónomos que, para propósito del modelaje, actúan como un componente integrado indivisible.

La ventaja fundamental del enfoque bottom-up es que normalmente se conoce el funcionamiento de un componente individual el cual se puede integrar con otros componentes por medio de funciones matemáticas para determinar el comportamiento de un conjunto integrado de componentes.

Figura 3: Modelamiento bottom-up de activos en sistemas PHM



Fuente: Al-Ahmar et al. (2008)

3.3.5 Sistemas PHM “Cerrados”

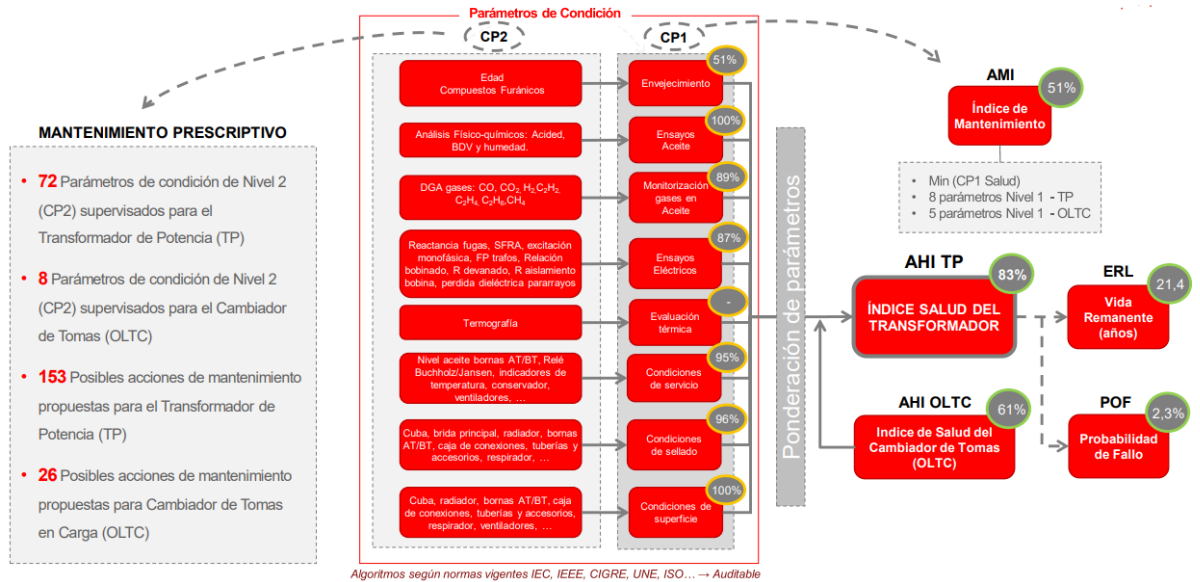
La tendencia tecnológica de la metodología PHM es producir sistemas PHM “cerrados” y acoplados a componentes específicos para que realicen de manera distribuida todo el procesamiento PHM requerido para controlar el componente. Esto es viable debido a la potencia computacional de los “super micro” computadores (computadores en el borde) que pueden realizar complejos procesamientos, y cuyo tamaño facilita que sean parte del activo industrial como procesadores de medición y/o procesamiento de datos.

Un sistema PHM cerrado es una colección de uno o más sensores diferentes que:

- Adquiere y transmite datos;
- Procesa y analiza los datos;
- Almacena información;
- Incorpora capacidad local para resolver problemas de funcionamiento.

A modo de ejemplo, la siguiente figura ilustra la aplicación del sistema PHM. El diagrama representa el modelo de salud de un transformador de potencia 55/12kV – 30MVA bajo monitorización continua de gases. El modelo estima la vida remanente en años y probabilidad de fallo en porcentaje a partir del análisis de unos parámetros de condición (gases de aceite, ensayos varios, evaluación termográfica o condiciones de estanqueidad). El sistema PHM cerrado del transformador (distribuido) reduce el riesgo de fallas graves en la infraestructura eléctrica a la que pertenece, gracias a la monitorización local e integral de su salud, en tanto que es un activo fundamental y crítico en el sistema eléctrico.

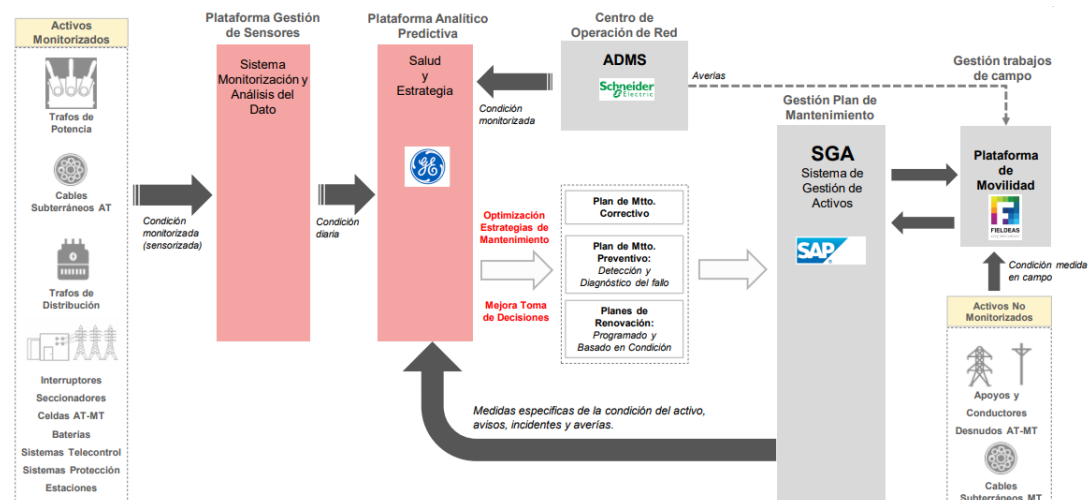
Figura 4: Modelo Pronóstico de la Salud del Transformador de Potencia



Fuente: Gonzalez (2021)

Como ilustra la siguiente figura, la idea final es que los activos eléctricos dispongan de componentes PHM, que ejecuten autónomamente, y de forma distribuida, el proceso PHM para proteger el activo, y por dicha vía a los usuarios, de fallas graves que impliquen interrupción del funcionamiento de la red de componentes PHM y por ende de los impactos negativos que esto conlleva. Los sensores PHM actúan de manera autónoma al tomar decisiones locales y transmiten datos a otros sistemas PHM o a un controlador PHM que se encarga de tomar las decisiones que afectan al activo como un todo.

Figura 5: Digitalización del proceso. Mantenimiento Inteligente.



Fuente: Gonzalez (2021)

4 Modelamiento de las Componentes: PHM Predictivo y de Pronóstico

El objetivo de este capítulo es presentar las metodologías analíticas predictivas empleadas para conocer el comportamiento de los activos a partir del conocimiento de la salud de sus componentes. Se revisarán los conceptos matemáticos fundamentales para llevar a cabo la implementación de lo que denominaremos PHM Predictivo y de Pronóstico.

4.1 Enfoques en PHM

Parte fundamental del PHM es el pronóstico, que se debe realizar con modelos de analítica avanzada predictiva. Existen tres enfoques para abordar la analítica predictiva:

- **Basado en modelos (físicos):** el proceso de degradación que conduce a la falla se describe a partir de modelos matemáticos de ecuaciones (diferenciales o algebraicas) derivadas del sistema físico. Los enfoques basados en modelos son más precisos que otros enfoques y tienen un horizonte de predicción de la Vida Útil Restante (RUL) a largo plazo, pero necesitan el conocimiento científico de un experto basado en la comprensión de la dinámica del sistema. Formular modelos de sistemas físicos reales es desafiante debido a la complejidad de los sistemas reales, y al comportamiento de la degradación estocástica del componente.
- **Basados en datos:** contruidos a partir de la información de los datos recopilados a través de sensores instalados en lugar de construir modelos físicos. Los enfoques basados en datos se pueden aplicar fácilmente en problemas de predicción y requieren más tiempo computacional que los enfoques basados en modelos (físicos). La precisión de los enfoques basados en datos depende en gran medida de la cantidad de datos disponibles. Se utilizan métodos probabilísticos, algoritmos basados en redes neuronales artificiales (ANN, Artificial Neural Nets) y en “Machine Learning” (ML). Algunas técnicas de ejemplo, entre muchas, son:
 - Análisis de regresión.
 - Redes neuronales artificiales (ANN).
 - Actualizaciones bayesianas.
 - Máquinas vectoriales de soporte (SVM).
- **Híbridos:** tanto los enfoques de pronóstico basados en modelos como los basados en datos tienen sus propios méritos y limitaciones. Un ejemplo de enfoque híbrido son las metodologías de estimación de estado, siendo la más conocida la del Filtro de Kalman (surgió en la década de los años sesenta y es descrita algo más en detalle en secciones posteriores) y todas sus variantes (Kalman, 1960). El enfoque de pronóstico híbrido es el vigente, ya que integra las ventajas de los dos enfoques (basado en modelos y en datos) lo que minimiza sus limitaciones. Por este motivo existe una clara tendencia por la integración del Filtro de Kalman con ANN en analítica predictiva avanzada.

4.2 Analítica Predictiva

A continuación, se ven tres metodologías básicas utilizadas en PHM en los diagnósticos de falla y estimación de la vida útil remanente de los componentes (a hasta la próxima falla).

4.2.1 Muestra Histórica

Convencionalmente, en analítica predictiva, el tiempo se divide en varios segmentos:

- Histórico: período para el que existen datos;
- Entrenamiento: corresponde a una parte del período histórico que se utiliza para estimar los parámetros de los modelos matemáticos. Por lo general, utiliza un modelo que minimiza una función de penalización por error;
- Prueba: corresponde a una parte del período histórico que se utiliza para validar los parámetros calibrados para los modelos. Los indicadores estadísticos se utilizan normalmente para medir la calidad del modelo matemático;
- Pronóstico: El modelo calibrado se utiliza después del historial para el que se realiza la predicción.

Esta división del tiempo es independiente de las metodologías matemáticas.

4.2.2 Estimación de Estado

En teoría de control, un estimador de estado es un sistema que proporciona una estimación del estado interno de un sistema real dado, a partir de mediciones de la entrada y salida del sistema real, se implementa en un computador y proporciona la base de muchas aplicaciones prácticas.

Conocer el estado del sistema es necesario para resolver muchos problemas de la teoría del control; por ejemplo, el control con retroalimentación de estado de la potencia reactiva importada y/o exportada por un generador solar fotovoltaico para mantener la tensión del punto de conexión a red dentro de los límites marcados por el código de red.

Filtro (Estándar) de Kalman

Los fundamentos matemáticos de ES fueron utilizados por R.E. Kalman y R.S Bucy para desarrollar la metodología comúnmente conocida como el Filtro de Kalman (KF, Kalman Filter) que se convirtió en una metodología ampliamente utilizada en todo lo relacionado con analítica predictiva.

El Anexo C incluye referencias de literatura donde se presenta de manera detallada la formulación matemática de KF, de sus extensiones y sus mejoras. Estos modelos son empleados en implementaciones de PHM donde las variables de estado incluyen: i) la falla, ii) el indicador de salud del activo (HI) y iii) el RUL.

KF tiene numerosas aplicaciones en tecnología e ingeniería. Inicialmente, las aplicaciones de la vida real eran para la guía, la navegación y el control de vehículos, particularmente aeronaves, naves espaciales, misiles y naves posicionadas dinámicamente. KF es un concepto ampliamente aplicado en el análisis de series temporales utilizado en campos como el procesamiento de señales y la econometría, también es uno de los temas principales en el campo de la planificación y el control del movimiento robótico y se puede utilizar en la optimización de trayectoria de un sistema. Debido al retraso de tiempo entre la emisión de comandos motores y la recepción de retroalimentación sensorial, KF es un modelo realista para hacer estimaciones del estado actual del sistema motor y emitir comandos actualizados. Otro campo de aplicaciones de KF es pronosticar variables hidro-climáticas, procesamiento de imágenes y en general es una de las metodologías más sólidas de la analítica predictiva.

Existen múltiples variantes del Filtro de Kalman; las más comunes son el Filtro de Kalman Centralizado o CKF (todas las mediciones se entregan a un centro de fusión y se procesan juntas) y el Filtro de Kalman Distribuido o DKF. Cuando el KF se trata de sistemas dinámicos complejos a gran escala con sus mediciones distribuidas en una gran cantidad de sensores, el CKF, aunque posiblemente sea óptimo, no proporciona robustez y escalabilidad. Las razones son dos:

- Los sistemas a gran escala son de muy alta dimensión y, por lo tanto, se requieren cálculos extensos para implementar el procedimiento centralizado; y
- El tamaño del sistema sobre el cual se despliega el sistema a gran escala, o se observa el fenómeno físico, plantea una gran carga de comunicación y, por lo tanto, entre otros problemas, agrega latencia (suma de retrasos temporales dentro de una red de datos) lo que complica las aplicaciones en tiempo real.

Por lo tanto, junto con las redes de sensores, el filtrado distribuido (DKF) puede beneficiar a múltiples aplicaciones, como PHM de activos eléctricos distribuidos.

4.2.3 Aplicación de la Inteligencia Artificial al Sector Eléctrico

El objetivo de este párrafo es relacionar las metodologías descritas en este estudio con el sector eléctrico.

Como se describe en esta nota, la Inteligencia Artificial (IA) se aplica cada vez más en el sector eléctrico, ayudando a mejorar la eficiencia, fiabilidad y seguridad de los sistemas eléctricos. He aquí algunos ejemplos de cómo se utiliza la IA en el sector eléctrico:

- Mantenimiento predictivo: La IA se utiliza para predecir averías en los equipos, analizando los datos de los sensores instalados en los equipos eléctricos. Esto permite a los equipos de mantenimiento identificar y solucionar los problemas antes de que provoquen una avería;
- Optimización de la red eléctrica: Los algoritmos de IA pueden analizar datos de los sistemas de generación, transmisión y distribución de energía para optimizar el flujo de electricidad y minimizar las pérdidas de transmisión;
- Previsión energética: La IA puede utilizarse para prever la demanda y la producción de energía, lo que ayuda a las empresas de servicios públicos a planificar las necesidades energéticas futuras y optimizar la generación y distribución de energía;
- Respuesta a la demanda: La IA puede ayudar a las empresas de servicios públicos a gestionar los programas de respuesta a la demanda mediante la predicción de los picos y valles de la demanda y el ajuste automático del suministro eléctrico para que coincida;
- Equilibrio de carga: La AI puede equilibrar la carga en una red eléctrica ajustando automáticamente la distribución de electricidad en diferentes regiones, reduciendo así el riesgo de cortes de energía.

Uno de los principales problemas de las empresas eléctricas es maximizar el rendimiento del sistema a corto y largo plazo. En general, es muy importante que las empresas y los gobiernos dispongan de una previsión lo más exacta posible de la demanda energética a corto y largo plazo. Esto permite a los operadores planificar eficazmente la asignación de recursos. La aplicación de la inteligencia artificial a la previsión ha demostrado su capacidad para mejorar y optimizar el rendimiento. La principal ventaja reside en que dicha aplicación no requiere la aplicación de complejas fórmulas matemáticas para correlacionar los datos de entrada y su salida (Metaxiotis et al., 2003).

Por ejemplo, la RNA se introdujo en el contexto de la previsión de la carga eléctrica a corto plazo (STELF). Esta metodología se ha aplicado, por ejemplo, para evaluar la corrección entre las

variaciones climáticas y la carga eléctrica necesaria. El método RNA también se ha utilizado para predecir la carga basándose en el historial de la demanda en función del día de la semana, la hora del día y la temperatura.

4.3 Proceso PHM

Las técnicas de monitoreo basado en la condición (CBM) y la predicción de la Vida Útil Restante (RUL) son características importantes de las estrategias de mantenimiento predictivo de los métodos de PHM, cuyos pasos son:

1. Adquisición y validación de datos;
2. Detección de degradación;
3. Diagnóstico;
4. Pronóstico;
5. Optimización de las decisiones.

4.3.1 Validación de Datos

La detección del malfuncionamiento se realiza a través de la validación de datos del sensor y se ha abordado mediante diferentes métodos de analítica predictiva, como, por ejemplo:

- Support Vector Data Description (SVDD)
- Plane-Based One-Class Support Vector Machine (PSVM)

4.3.2 Diagnostico

Analíticamente el PHM se centra en dos pasos fundamentales: diagnóstico y pronóstico. El diagnóstico se utiliza para analizar las tendencias que se establecen en las características y para determinar la causa raíz de los fallos y la degradación de los componentes.

El diagnóstico implica la detección, el aislamiento y la identificación de las fallas.

4.3.3 Pronóstico

Pronóstico es la estimación de la Vida Útil Restante (RUL), una disciplina de ingeniería centrada en predecir el momento en que un sistema o un componente ya no realizará su función prevista como consecuencia de: i) el estado actual y del anterior, y ii) las condiciones operativas actuales y futuras. Los métodos PHM combinan la detección, la recopilación de datos, la interpretación de parámetros ambientales, operativos y relacionados con el rendimiento para indicar la salud de los sistemas, así como anticipar la propagación del daño debido a la degradación. El Pronóstico es esencial para mejorar la seguridad, confiabilidad y disponibilidad del sistema.

Las metodologías de PHM estudian las variaciones de los parámetros, que indican cambios en la degradación del rendimiento, como función de la duración y de las condiciones de uso. Esta falta de rendimiento suele ser una falla más allá de la cual el sistema ya no se puede usar para cumplir con el rendimiento deseado. El tiempo previsto se convierte entonces en la vida útil restante RUL, que es un concepto importante en la toma de decisiones para la mitigación de contingencias.

Para llevar a cabo el proceso es necesario definir:

- Umbral crítico de falla.
- Umbral de Falla.
- Modelo de degradación.
- Degradación estimada.
- Límites de confianza.
- Mediciones.

4.4 Modelado PHM del RUL

Tradicionalmente, los enfoques de PHM son esencialmente la extrapolación de tendencias basadas en observaciones recientes para estimar el remanente de la vida útil (RUL) y el final de la vida del activo (End-of-Life, EoL). Si no se comprenden las medidas correspondientes a la incertidumbre asociada con el cálculo, las proyecciones de RUL tienen poco valor científico, ya que los enfoques tradicionales son en gran medida cualitativos y se centran en pocos indicadores al final de la vida útil de diseño e incluso cuando el activo ha excedido su esperanza de vida. Es la comprensión de las incertidumbres correspondientes lo que permite desarrollar un modelo de negocio realista que aborde los requisitos de Pronóstico. El lector interesado en profundizar en el modelado PHM de diagnóstico y pronóstico puede consultar las referencias literarias del Anexo C.

Una vez tenemos completo el análisis de PHM predictivo y de pronóstico, disponemos de información de gran valor sobre la salud de los componentes de nuestro activo (RUL, EoL, Indicadores de salud). Esta información de gran valor que nos brinda la analítica predictiva y de pronóstico, servirá de base para la implementación de un mantenimiento óptimo o inteligente de maximización de beneficios para la organización.

En la siguiente sección veremos esta última parte de optimización en el mantenimiento inteligente, conocida como PHM prescriptivo o de optimización.

5 Optimización de la Red de Activos Eléctricos: PHM Prescriptivo y de Optimización

El objetivo de este capítulo es presentar una visión general del uso de las metodologías analíticas prescriptivas para optimizar las decisiones relacionadas con los componentes, los activos y la red de activos, considerando que las plantas y los sistemas industriales (eléctricos) resultan de la integración de múltiples activos, lo que conlleva a la necesidad de conocer el comportamiento de las componentes. Para contribuir con este capítulo, el Anexo A presenta casos de uso sobre la aplicación real de técnicas de PHM en diversos tipos de sistemas.

5.1 Optimización del Mantenimiento

En general el punto común en todos los métodos de optimización es que la cantidad de presupuesto asignado a las actividades de mantenimiento es limitada y solo se estudia la inversión entre activos críticos. Por lo tanto, el problema, además de asignar adecuadamente el presupuesto entre los activos importantes del sistema (priorizando), es minimizar el monto total del presupuesto de mantenimiento. Para ello, se necesita comparar los índices de confiabilidad después de PM, para evaluar la efectividad de la estrategia de mantenimiento implementada. Es más, estos pueden ser parte del proceso de optimización.

El objetivo es minimizar el costo y maximizar la confiabilidad, objetivos en contradicción ya que si se desea mayor confiabilidad se debe asumir mayor costo. Por lo tanto, la optimización del problema de mantenimiento de activos es un problema multicriterio. Estos objetivos se logran optimizando uno o varios de los siguientes subobjetivos:

- Confiabilidad.
- Costo.
 - El costo total de producción/generación (despacho económico).
 - El costo de reemplazo (o mantenimiento correctivo) más el costo de reparación.
 - El costo de operación y mantenimiento.
 - El costo de confiabilidad, costo de interrupción.
- Riesgo.

5.2 Analítica Prescriptiva

Para resolver el problema matemático de la optimización (analítica prescriptiva) de un sistema se pueden utilizar varios enfoques, estos son:

- Modelos Mentales (intuición y buena voluntad).
- Simulación (modelo físico + razonamiento humano).
- Metaheurísticas (racionalamiento "inteligente").
- Machine Learning (experiencias, buenas prácticas).
- Programación Matemática (modelo físico + matemáticas de optimización).

De las anteriores alternativas, la única que es capaz de garantizar soluciones óptimas es la basada en las matemáticas, conocida como programación matemática o como métodos exactos. Para muchas compañías, líderes en la producción de tecnologías de analítica avanzada, como IBM, la optimización estocástica y la optimización determinística son las tecnologías analíticas que mayor ventaja competitiva producen y que dan mayor capacidad para manejar la complejidad. Por dicha

razón se propone utilizar modelos de programación matemática para resolver los problemas optimización de actividades de mantenimiento.

5.2.1 Modelos Mentales

Los modelos mentales, basados en la intuición y la buena voluntad, corresponden a una forma no-profesional de tomar decisiones, ya que desconoce todo el conocimiento científico desarrollado sobre el tema, partiendo del principio que “cualquier decisión que un ser humano pueda calcular” es buena siempre que se tome con buena intención e idoneidad personal, pero no con conocimiento científico. Esta posición descalifica la ingeniería como uno de los soportes de la evolución tecnológica de la humanidad.

5.2.2 Simulación

La decisión con base en los modelos de simulación se basa en dos pasos:

- Construcción de un modelo de simulación del proceso físico (puede ser un modelo basado en ecuaciones diferenciales).
- Uso del modelo de simulación para resolver preguntas “what if” de forma de poder evaluar el impacto de las decisiones.

El proceso se basa en que un profesional experto en el tema, con base en algún criterio (experiencia, lógica, intuición, entre otros), realiza secuencialmente preguntas al modelo y toma la decisión analizando el conjunto de respuestas disponibles. Este proceso, difícilmente produce decisiones óptimas, ya que el proceso de generar las preguntas itera con base en un ser humano que tiene limitaciones para seleccionar las políticas/decisiones que pueden ser óptimas. Sin embargo, para procesos simples, pueden ser de mucha utilidad.

5.2.3 Metaheurísticas

Una heurística es una técnica matemática diseñada para resolver un problema rápidamente cuando los métodos clásicos son demasiado lentos para encontrar una solución exacta. Esto se logra intercambiando la optimalidad, la integridad, la exactitud o la velocidad. En cierto modo, puede considerarse un atajo para aproximarse a la solución exacta. Las heurísticas se diseñan para cada tipo de problema específico, y no tienen validez universal.

Una metaheurística es un método heurístico para resolver un tipo de problema computacional general, usando los parámetros dados por el usuario sobre unos procedimientos genéricos y abstractos, de una manera que se espera eficiente. Normalmente, estos procedimientos son heurísticos. El nombre combina el prefijo griego “meta” (“más allá”, aquí con el sentido de “nivel superior”) y “heurístico” (que significa descubrir, encontrar).

Las metaheurísticas generalmente se aplican a problemas que no tienen un algoritmo, o una heurística específica que dé una solución satisfactoria; o bien cuando no es posible implementar ese método óptimo. La mayoría de las metaheurísticas tienen como objetivo los problemas de optimización combinatoria, pero por supuesto, se pueden aplicar a cualquier problema que se pueda reformular en términos heurísticos, por ejemplo, la solución de ecuaciones booleanas.

Dado que las heurísticas y las metaheurísticas pertenecen a problemas específicos, no se analiza la solución del problema en referencia utilizando estas metodologías. Solo se deja presente que tratan de resolver rápidamente un problema de optimización y que no es fácil de probar que las soluciones obtenidas son óptimas, en la mayoría de los casos son “buenas” soluciones.

5.2.4 Machine Learning

En general, tomar decisiones basadas en la experiencia, las que podemos denominar buenas prácticas. Estas pueden provenir de modelos mentales aceptados por el decisor o de modelos matemáticos basado en metodologías de clasificación, como pueden ser las Maquinas de Vectores de Soporte (SVM).

Con SVM las decisiones se tomarán con base en los datos históricos, los cuales deben asociarse a decisiones exitosas y decisiones fallidas (clasificación cualitativa, que puede ser subjetiva, y que no está asociada a seleccionar matemáticamente un punto como la mejor solución). El SVM proporcionará una regla matemática (un hiperplano) para determinar la frontera que divide el éxito del fracaso. La decisión por tomar debe estar en la zona exitosa. Este proceso no produce decisiones óptimas, ya que la clasificación depende de una regla clasificada subjetivamente como exitosa.

5.2.5 Optimización Matemática

La Programación Matemática (Mathematical Programming, MP), también llamada Optimización, hace referencia a la acción y efecto de optimizar, que es la selección del mejor elemento (con respecto a algún criterio) de un conjunto de elementos disponibles/factibles. En el caso más simple, consiste en maximizar o minimizar una función real eligiendo sistemáticamente valores de entrada (tomados de un conjunto permitido) y computando el valor de la función. La generalización de la teoría de la optimización y técnicas para otras formulaciones comprende un área amplia de las matemáticas aplicadas. En términos generales de mantenimiento, optimización se refiere a la capacidad de resolver un problema matemático encontrando la manera más eficiente posible y utilizando la menor cantidad de recursos.

Las leyes matemáticas que rigen a la optimización son sólidas (datan de hace más de 400 años) y se presentan en resumen en el siguiente numeral. Son el soporte de todas las metodologías y tecnologías que hoy en día conforman la MP. Para casos reales, para solucionar modelos de optimización se requiere de un algoritmo especializado (solver) en resolver problemas de programación matemática. La solución proporcionada por el solver no puede ser superada por cualquier otra metodología. Se debe tener en cuenta que el tiempo de solución del problema de optimización depende de la calidad del “solver”.

5.3 Gestión de Riesgos

Consciente o inconscientemente siempre asumimos riesgos. La Gestión de Riesgos científica, financiera y operativa, es el verdadero beneficio que proporcionan los modelos de optimización estocástica. La complejidad de este problema radica en su naturaleza bi-criterio: i) maximizar la recompensa esperada y ii) minimizar el riesgo asumido. La gestión de riesgos utilizando modelos de riesgo neutrales, que optimizan el valor esperado de la función objetivo, excluyendo las metodologías de gestión de riesgos basadas en medidas de riesgo (como CvaR, Conditional Value-At-Risk), conducen al sistema a posiciones peligrosamente vulnerables (posiciones de alto riesgo).

Existen múltiples tipos de criterios para medir los riesgos e introducirlos como parte del proceso de toma de decisiones:

- Valor esperado de ingresos;
- Varianza media;

- Minimax;
- Arrepentimiento máximo;
- Riesgo a la baja;
- Riesgo mínimo más restricciones de ingresos esperados;
- Valor esperado más restricciones de riesgo.

5.4 Modelamiento de los Componentes

Para efectos de modelamiento matemático, los activos se representan por medio de una estructura jerárquica multinivel que en el nivel superior corresponde a una suma de elementos, los cuales se clasifican de acuerdo con su jerarquía. Al mayor nivel está el “activo integrado” que está compuesto por sistemas, cada uno de los cuales puede estar compuesto por un conjunto de subsistemas, cada uno de los cuales puede estar compuesto por un conjunto de componentes, correspondiendo éstos al último nivel del árbol jerárquico y que, normalmente, corresponde al sitio donde se produce la falla que afecta a todos los elementos en la rama de la estructura jerárquica. La conectividad de los componentes y subsistemas debe considerarse para determinar el estado del activo como un todo. Se deben considerar dos tipos de conectividad:

- Serie: la falla de un componente determina la no operabilidad de todos los elementos en el árbol a partir del componente que falla
- Paralelo: la falla de un componente implica la pérdida de productividad/capacidad a partir del componente que falla.

5.5 Optimización Individual de Activos

Desde el punto de vista de mantenimiento, la optimización del uso de un activo corresponde a un modelo de optimización estocástica que se corre individualmente para cada activo con el objetivo de determinar el tiempo operacional óptimo hasta la próxima parada para mantenimiento, y el costo correspondiente. Los resultados se concretan en dos conjuntos de activos:

- Los que pueden operarse durante el próximo horizonte de planificación.
- Los que deben ir a mantenimiento durante el próximo horizonte de planificación.

Dado que los activos están integrados por componentes, los cuales pueden ser objeto de actividades individuales de mantenimiento, la optimización del mantenimiento de un activo implica la optimización del mantenimiento de los componentes, lo que lo convierte en un proceso complejo.

5.6 Optimización de la Red de Activos

Para el análisis de la programación óptima de actividades de mantenimiento de la red de activos se requieren dos modelos de optimización:

- OIAM (Optimization of Individual Asset Maintenance): Mantenimiento individual del activo.
- OANM (Optimization of Asset Network): Mantenimiento de la red de activos.

Los modelos OIAM y OANM pueden integrarse en un solo modelo, lo que es viable para pequeñas redes; sin embargo, para casos reales debido a la cantidad de los activos y/o a la complejidad derivada de la cantidad de escenarios sintéticos, su optimización integrada puede no ser posible (o conveniente) requiriéndose de modelos individuales para optimizar la operación de cada activo, cuyos resultados serán input del modelo integrado de planificación del mantenimiento de la red de activos.

Como hemos visto a lo largo de este capítulo, el concepto de analítica prescriptiva o PHM de optimización puede abordarse de diferentes formas dependiendo de la complejidad y necesidades de optimización del sistema de activos. El lector interesado en profundizar en el modelado PHM de diagnóstico y pronóstico puede consultar las referencias literarias del Anexo C.

5.7 Tabla de Resumen

Metodologías	Principal Sub-Sectores	Principales Tecnologías
Optimización del mantenimiento	El sector más afectado es el de la producción, donde hay un gran número de componentes a mantener y donde las paradas planificadas e imprevistas para el mantenimiento tienen un efecto directo sobre el coste y la disponibilidad de la electricidad. También intervienen el transporte y la distribución, ya que, aunque haya menos componentes, un correcto mantenimiento permite limitar costes y evitar interrupciones del servicio.	IoT, Big Data, Smart Metering
Analítica Prescriptiva	En este caso, la producción y la distribución son los subsectores más afectados. Por ejemplo, la optimización puede tener lugar en la gestión del activo de producción, considerando como un sistema todos los componentes necesarios para la generación. De manera similar, en distribución, el sistema puede optimizarse considerando los diversos activos distribuidos (por ejemplo, almacenamiento y micro producciones).	IoT, Big Data, Smart Metering
Gestión de Riesgos	Todos los subsectores se ven afectados, cada uno por sus riesgos típicos. De hecho, la IA ayuda a evaluar constantemente la probabilidad real de que ocurra un escenario (por ejemplo, mal funcionamiento o rotura), teniendo en cuenta los grandes datos que provienen del sistema y evaluando las aceleraciones o ralentizaciones de la función.	Inteligencia Artificial, Machine Learning
Modelamiento de los Componentes	La IA aplicada al análisis del árbol de fallas es más efectiva en un sistema donde el número y las correlaciones entre componentes son mayores. En este sentido, el subsistema de producción es el que se puede beneficiar más.	Inteligencia Artificial, Machine Learning, Realidad Virtual, Gemelos Digitales
Optimización Individual de Activos	En ambos casos, los sectores aquí implicados son tanto el de transmisión como, sobre todo, el de distribución. Esto se debe a que la IA permite evaluaciones integrales y holísticas en toda la red.	Inteligencia Artificial, Machine Learning
Optimización de la Red de Activos		

6 Conclusiones

El estudio ofrece una visión global sobre la importancia de abordar el Mantenimiento de Activos en el marco de las Tecnologías de Inteligencia Artificial mediante la implementación de metodologías de analítica avanzadas (Mantenimiento Pronóstico de la Salud, Prognostic Health Maintenance o PHM) como camino prácticamente indispensable para modernizar y mejorar la competitividad del sector eléctrico.

Los modelos de mantenimiento tradicionales orientados a un mantenimiento preventivo o correctivo ya no son suficientes para optimizar el rendimiento de los componentes (y por ende del sistema). La implementación de mantenimiento predictivo, de diagnóstico y prescriptivos son claves para alcanzar los objetivos de disponibilidad, rendimiento y reducción de costes.

El concepto de uso de las nuevas tecnologías (IA, IoT, Big Data) al servicio de las analíticas avanzadas (predictiva y prescriptiva) para la toma de decisiones inteligentes en el mantenimiento de la infraestructura eléctrica tiene infinidad de aplicaciones dentro del mismo sector eléctrico y en otros ámbitos de la organización. En el contexto actual de gestión de activos del sector eléctrico, la competencia es cada vez mayor y los costes fijos, de producción/distribución y mano de obra también van en aumento, afectando los márgenes de utilidad que se ven reducidos. El aumento de la disponibilidad y rendimiento de los activos y reducción de costes de mantenimiento son vitales.

Los modelos analítica predictiva, de pronóstico y analítica prescriptiva en el mantenimiento (PHM predictivo, de pronóstico y de optimización), en conjunción con las tecnologías de inteligencia artificial / machine learning y los sistemas de información modernos relacionados con Industria 4.0, son los pilares funcionales del proceso de transformación digital y vitales para garantizar la disponibilidad y usabilidad requerida de los equipos e instalaciones (vida útil), minimizando los costes de mantenimiento dentro del marco de la seguridad y del medio ambiente.

Los beneficios inmediatos de la implementación de PHM en el mantenimiento son la reducción de acciones correctivas y sus costes asociados, gracias a un modelado de vida útil que anticipa fallos y define acciones de mantenimiento optimizadas. Se estima que la aplicación de mantenimiento de PHM predictivo, de pronóstico y de optimización supone en media un beneficio (o ahorro en costes de mantenimiento) de entre un 18-25% en comparación con mantenimientos tradicionales preventivos y correctivos.

Con la presente NT se pretende mostrar a los agentes públicos, propietarios, operadores, gerentes de activos del sector eléctrico, la importancia de la implementación del mantenimiento inteligente con el uso de analíticas avanzadas y las nuevas tecnologías, y se invita y recomienda a profundizar más en este campo contactando con expertos del sector y buscando financiación adecuada. La digitalización del sector eléctrico brinda beneficios a todas las partes involucradas, desde la reducción de costes de mantenimiento y aumento de utilidades, aumento del rendimiento de los activos, confiabilidad y calidad de servicios. Como resultado de la optimización de costes, el usuario final se verá beneficiado con una oferta de tarifas más competitivas.

Anexos

A. Casos de Uso en el Sector Eléctrico

La siguiente tabla muestra los casos de uso descritos en este anexo:

Casos de Uso	Aplicación	Objetivos Principales
PHM en Plantas de Generación de Energía Eléctrica	Turbina de Gas Equipada con PHM Turbina Eólica Celdas Fotovoltaicas Almacenamiento de Energía de la Red	Optimización y maximización de la capacidad productiva
Mantenimiento de Subestaciones Eléctricas	Análisis de Gases Disueltos PHM vía Red Neuronal Probabilística Algoritmo de Optimización de las Ballenas Caso Power Supply Company	Optimización del mantenimiento y reducción de riesgos
Mantenimiento Integral de Sistemas de Generación de Electricidad	Optimización bajo Incertidumbre Mantenimiento en Plantas Industriales Eléctricas Empresa Generadora de Electricidad Sistema Interconectado Implementación Computacional Modelamiento del Riesgo	Optimización del mantenimiento del sistema de Generación y reducción de riesgos
Sistemas Aéreos No-Tripulados para Servicios Públicos de Energía	VRP: Vehicle Routing Problem with RUL Control Inspección Visual de Líneas Eléctricas Inspección Rutinaria de Líneas y Torres Inspección del Corredor de Línea Gestión de Emergencias	Optimización del mantenimiento, reducción de riesgos y evaluación de escenarios

A.1. PHM en Plantas de Generación de Energía Eléctrica

La ventaja de un sistema PHM sobre un sistema de monitoreo es que un sistema PHM es capaz de predecir fallas basadas en “precursores de fallas”. Determinar los precursores es difícil y, a menudo, requiere un extenso análisis histórico de los comportamientos del sistema ante los diferentes tipos de fallas. En algunos casos de falla, los precursores de falla pueden estar vinculados a modos de falla.

A continuación, se analizan varios casos de uso de aplicación de la metodología PHM en plantas de generación de energía.

A.1.1. Turbina de Gas Equipada con PHM

Descripción

Las turbinas de combustión (gas), que se están instalando en muchas de las centrales eléctricas de gas natural de hoy en día, son máquinas complejas, que involucran tres secciones principales:

- Compresor: atrae aire al motor, lo presuriza y lo alimenta a la cámara de combustión a velocidades de cientos de millas por hora.
- Sistema de combustión: típicamente compuesto por un anillo de inyectores de combustible que inyectan un flujo constante de combustible en las cámaras de combustión donde se mezcla con el aire. La mezcla se quema a temperaturas de más de 2000 grados °F. La combustión produce una corriente de gas de alta temperatura y de alta presión que entra y se expande a través de la sección de la turbina.
- Turbina: es un conjunto intrincado de palas de sección aerodinámica estacionarias o giratorias. A medida que el gas de combustión caliente se expande a través de la turbina, hace girar las palas/cuchillas que realizan una doble función: i) impulsan el compresor para atraer más aire a presión a la sección de combustión, y ii) hacen girar un generador para producir electricidad.

La eficiencia de la conversión de combustible a energía depende de la temperatura a la que funciona, las más altas generalmente significan mayores eficiencias, lo que, a su vez, puede conducir a una operación más económica. El gas que fluye a través de una turbina típica de una planta de energía puede estar tan caliente como 2300 °F, pero algunos de los metales críticos en la turbina pueden soportar temperaturas tan calientes como 1500 °F a 1700 °F. Por lo tanto, el aire del compresor podría utilizarse para enfriar componentes de la turbina, lo que reduce la máxima eficiencia térmica. Las turbinas avanzadas soportan temperaturas de entrada hasta 2600 °F y logran eficiencias hasta del 60 por ciento.

Otra forma de aumentar la eficiencia es un recuperador o generador de vapor de recuperación de calor (HRSG) que recupera energía del escape de la turbina para precalentar el aire de descarga del compresor capturando el calor antes de que entre en la cámara de combustión. El vapor de alta presión de estas calderas se puede utilizar para generar energía eléctrica adicional con turbinas de vapor, una configuración llamada ciclo combinado.

Una turbina de gas de ciclo simple puede lograr eficiencias de conversión de energía que oscilan entre el 20 y el 35 por ciento. Es probable que las futuras plantas de ciclo combinado de turbinas de gas alimentadas con hidrógeno y syngas logren eficiencias del 60 por ciento o más. Cuando el calor residual se captura de estos sistemas para calefacción o con fines industriales, la eficiencia general del ciclo energético podría acercarse al 80 por ciento. El syngas, o gas de síntesis, es un combustible gaseoso obtenido a partir de sustancias ricas en carbono (hulla, carbón, coque, nafta, biomasa) sometidas a un proceso químico a alta temperatura.

PHM

El Pronóstico y Gestión de Salud (PHM) para una turbina a vapor está compuesto por:

- Los sensores,
- Colecciones de datos,
- Procesamiento de señales,
- Monitoreo de condición y evaluación de la salud del activo,
- Razonamiento físico,

- Modelos físicos,
- Modelos basados en la experiencia
- Modelos basados en las propiedades estadísticas de los componentes,
- Técnicas de modelado y análisis de datos,
- Soluciones numéricas a las ecuaciones que describen el sistema físico, y
- Toma óptima de decisiones.

El modelo físico no-lineal de la dinámica del sistema se utiliza como ecuación de estado en el algoritmo del Filtro de Kalman (KF) o de una de sus variaciones y/o mejoras. KF se utiliza para validar el modelo físico de la turbina y las medidas de los sensores (que proporcionan información imperfecta sobre el estado actual de la turbina). En la práctica industrial eléctrica, el PHM de una turbina se basa en cientos de sensores que rastrean los estados de salud de un gran número de componentes con diferentes impactos en el funcionamiento integral de la turbina.

Para el lector interesado en conocer con más detalle la teoría del KF, se le invita a consultar el Anexo C del presente documento.

A.1.2. Turbinas Eólicas

La energía eólica ha estado creciendo exponencialmente en todo el mundo desde el año 2000. Para el año 2020, había más de 550.000 turbinas eólicas en funcionamiento, con una capacidad nominal total de 742.482 MW. El DoE (Departamento de Energía de EE. UU.) afirma que es técnicamente factible cumplir su objetivo del 20% de los requisitos energéticos totales para 2030, pero esto implica investigación y desarrollo en todos los aspectos, como el diseño estructural, la fabricación, la operación, el mantenimiento, y la construcción de los sistemas de generación eólica. A pesar de los hechos exitosos también existen algunos riesgos ocultos y preocupaciones para todos los jugadores. Además de la inversión inicial para la construcción de las turbinas, se estima que la operación y el mantenimiento a lo largo de su vida útil representan 20–25% del costo total de las turbinas en tierra y el 18% para las turbinas en alta mar, y puede aumentar al 30–35% de la participación del costo al final de la vida.

El PHM juega un papel importante en la promoción del desarrollo de la energía eólica y la reducción de los costos de operación al garantizar que las turbinas eólicas sean más confiables y productivas. La imagen presenta el estado del desarrollo de las turbinas eólicas, cuya eficiencia depende del tamaño, lo que conlleva que para su uso eficiente se desarrollaran “inmensas” turbinas eólicas con capacidades de generación al menos 20 veces más grande que las actuales turbinas “convencionales”.

Según Wind System Magazine, el 70% de los costes totales de mantenimiento de los aerogeneradores se deben a averías no programadas; para un parque eólico de escala de 100 MW, solo el 1% del aumento de disponibilidad puede valer entre \$ 300-500 KUSD de ingresos por año. La European Wind Energy Association (EWEA) sugiere que el monitoreo de condición es un sistema crítico e integral para la operación y el mantenimiento de este tipo de activos es fundamental (Pineda et al., 2014).

Los sistemas de monitorización existentes para turbinas eólicas se dividen principalmente en dos categorías:

- Sistema de Control Supervisado y Adquisición de Datos (SCADA) y
- Sistema de Monitorización de Estado (Condition Monitoring Systems, CMS).

El SCADA tiene una variedad de sensores para recopilar datos de componentes críticos y entornos externos. Los datos se utilizan como entradas para los sistemas de control (entre varios) de ángulo, cabeceo, giro y frenado. Un CMS tiene principalmente acelerómetros y sensores montados en las partes críticas de transmisión y de generación. El nivel de vibración y las características relacionadas se utilizan para evaluar las condiciones de salud de los componentes cercanos. Sin embargo, ninguno de los dos sistemas es más que un sistema de recopilación de datos, y el operador recibe información limitada e indirecta de los riesgos de operación para tomar decisiones de mantenimiento óptimas.

A continuación, se presentan enfoques para estimar la vida útil restante (RUL) y el comportamiento futuro de un sistema de generadores basado en turbinas eólicas. Como resultado, se enfatizan algunas aplicaciones pronósticas en sistemas de energía renovable, como dispositivos de convertidor de potencia, degradación de la capacidad de la batería y daños en los rodamientos de ejes de alta velocidad de turbinas eólicas.

La lista presenta una relación no exhaustiva de principales fallas de las componentes de un aerogenerador horizontal:

- Freno de palas de turbina.
- Incendios de aerogeneradores.
- Fallo del generador.
- Hielo en los carriles de las turbinas.
- Fallo del sistema de ("yaw").
- Fallo por fatiga.
- Fallo del rodamiento.
- Fallo de la caja de cambios.

Los modernos aerogeneradores que se utilizan para obtener energía duran unos veinte años. Si tenemos en cuenta que el índice de actividad es del 60% aproximadamente, pues se desconectan cuando el viento no alcanza potencia suficiente o si, por el contrario, es demasiado fuerte, pueden funcionar sin problemas más de 100.000 horas. Durante esas dos décadas es necesario realizar actividades de mantenimiento (se suelen revisar unas dos veces al año), que pueden ir desde una simple revisión de las diferentes piezas hasta la reparación de una avería inesperada o la lubricación de los componentes internos.

Para una inspección general del exterior o de las aspas se utilizan robots especializados que trepan por el lateral de la torre mediante un sistema de succión y envían imágenes de alta resolución a los ingenieros. Si es necesario acceder a la maquinaria, una portezuela lateral lleva a una escalera interna que sube hasta la cabina de la turbina. Allí, dos o más operarios se encargan de tareas de mantenimiento. Para arreglar las aspas se sale al exterior desde la cabina, con un equipamiento de seguridad especial; es una tarea compleja y peligrosa, dado que estas turbinas se instalan, lógicamente, en zonas caracterizadas por sus fuertes rachas de viento.

PHM

Para el PHM se pueden implementar varias tecnologías de monitoreo en turbinas eólicas, incluido el análisis de vibraciones, la medición acústica, el monitoreo del aceite de lubricación, la termografía infrarroja y la inspección visual. Estas tecnologías se pueden clasificar en dos categorías de monitorización: i) continua y ii) periódica. Las técnicas para el monitoreo continuo de la "salud" de las turbinas eólicas son ampliamente reconocidas por la industria como beneficiosas, pero económicamente costosas, especialmente para las turbinas en tierra (on-shore); para las turbinas marinas (off-shore) el monitoreo continuo se ha vuelto casi obvio, y su

creciente nivel ofrece una oportunidad importante para que la industria aproveche los beneficios del PHM y reduzca los costos de operación y mantenimiento. La articulación de los componentes de PHM se puede explicar de la siguiente manera: el propósito de la detección es identificar el estado de salud del sistema (en buenas o en defectuosas condiciones). Cuando se detecta una falla, el diagnóstico permite aislar e identificar el componente dañado; el pronóstico entonces apunta a proyectar el estado del sistema hacia el futuro. El ciclo PHM incluye 7 pasos: 1) adquisición de datos, 2) procesamiento de datos, 3) detección del estado, 4) diagnóstico, 5) pronóstico, 6) toma de decisiones y 7) interfaz hombre-máquina.

Pronóstico Híbrido

Un método de pronóstico híbrido es la combinación de un modelo de degradación física y un enfoque basado en datos para mejorar la capacidad de predicción; por otro lado, pueden ser consumidores en complejidad algorítmica y, también, están limitados por la necesidad de modelado físico de los fenómenos de degradación. El pronóstico se puede asimilar con la combinación de dos procesos fundamentales:

- Predicción (estimación) de la evolución del RUL y
- Clustering (agrupamiento) especificando si el sistema está en un estado u en otro.

Las técnicas utilizadas en estos dos métodos de predicción y agrupamiento tratan de aproximarse a una función que pueda explicar un vector de salida en función de las medidas disponibles (vector de entrada).

Caso de Uso

Las vibraciones son oscilaciones de un cuerpo cualquiera con respecto a un punto de referencia. Una fuente de vibración forzada se debe al desequilibrio de partes en rotación. Si el centro de gravedad de una masa tiene una excentricidad radial, la fuerza centrífuga generada por la rotación producirá que esta vibre, este es el caso cuando el eje de un motor no está balanceado. Las vibraciones de un cojinete de eje de alta velocidad (High-Speed Shaft Bearing, HSSB) sirven para determinar fallas en turbinas eólicas.

En este caso, durante 50 días, los datos de vibración HSSB de una turbina eólica Suzlon de 2,2 MW (velocidad típica del eje de 30 Hz. Proporcionado por en los EE. UU.) se registraron a una frecuencia de muestreo de 100 kHz (es decir, una adquisición cada 6 segundos). Lo que constituye una excelente oportunidad para probar algoritmos pronósticos.

La predicción de RUL se basa en una estimación de cargas y de velocidades futuras. Ciertamente, un generador de turbina eólica (wind turbine generator, WTG) tiene variabilidad en la velocidad, pero en promedio, es de aproximadamente 30 Hz; para predecir el RUL medio se utiliza el RPM medio.

A.1.3. Celdas Fotovoltaicas

La energía solar (solar energy, SE) es la luz radiante y el calor del sol que se aprovecha utilizando una gama de tecnologías como:

- La energía solar para generar electricidad,
- La energía solar térmica (incluido el calentamiento solar del agua) y
- La arquitectura solar.

SE es una fuente renovable y se caracteriza como pasiva o activa dependiendo de cómo capturan y distribuyen la energía solar y la convierten en potencia solar. Las técnicas solares activas incluyen el uso en:

- Sistemas fotovoltaicos.
- Energía solar concentrada.
- Energía solar térmica que se puede utilizar para el calentamiento de agua, la calefacción de espacios, la refrigeración de espacios y la generación de calor de proceso.

Las técnicas solares pasivas incluyen orientar un edificio hacia el sol, seleccionar materiales con masa térmica favorable o propiedades de dispersión de la luz, y diseñar espacios que circulen naturalmente el aire.

La Agencia Internacional de Energía (International Energy Agency, IEA), anunció que el desarrollo de tecnologías de energía solar asequibles, inagotables y limpias generará enormes beneficios a largo plazo. Aumentará la seguridad energética de los países a través de la dependencia de un recurso autóctono, inagotable (en su mayoría independiente de las importaciones), mejorará la sostenibilidad, reducirá la contaminación, reducirá los costos de mitigar el calentamiento global. Estas ventajas son globales (IEA, 2011).

La conversión de energía de la luz solar en electricidad se realiza:

- Directamente utilizando energía fotovoltaica (photovoltaic, PV) convirtiendo la luz en una corriente eléctrica. Utilizando el efecto fotovoltaico. La figura presenta un diagrama de la estructura de una planta de generación fotovoltaica.
- Indirectamente utilizando energía solar concentrada por medio de lentes o espejos y sistemas de seguimiento solar para enfocar una gran área de luz solar a un punto caliente, a menudo para impulsar una turbina de vapor.

La generación de energía solar creció un 23% el año pasado, y la eólica un 14%. Combinadas, llegan a más del 10% de la generación de electricidad mundial. Todas las fuentes de electricidad limpia generaron el 38% de la electricidad mundial en 2021, más que el carbón (36%). Sin embargo, el consumo de electricidad ha aumentado, lo que ha dado lugar a aumentos históricos en las emisiones y la energía con carbón (Jones, 202).

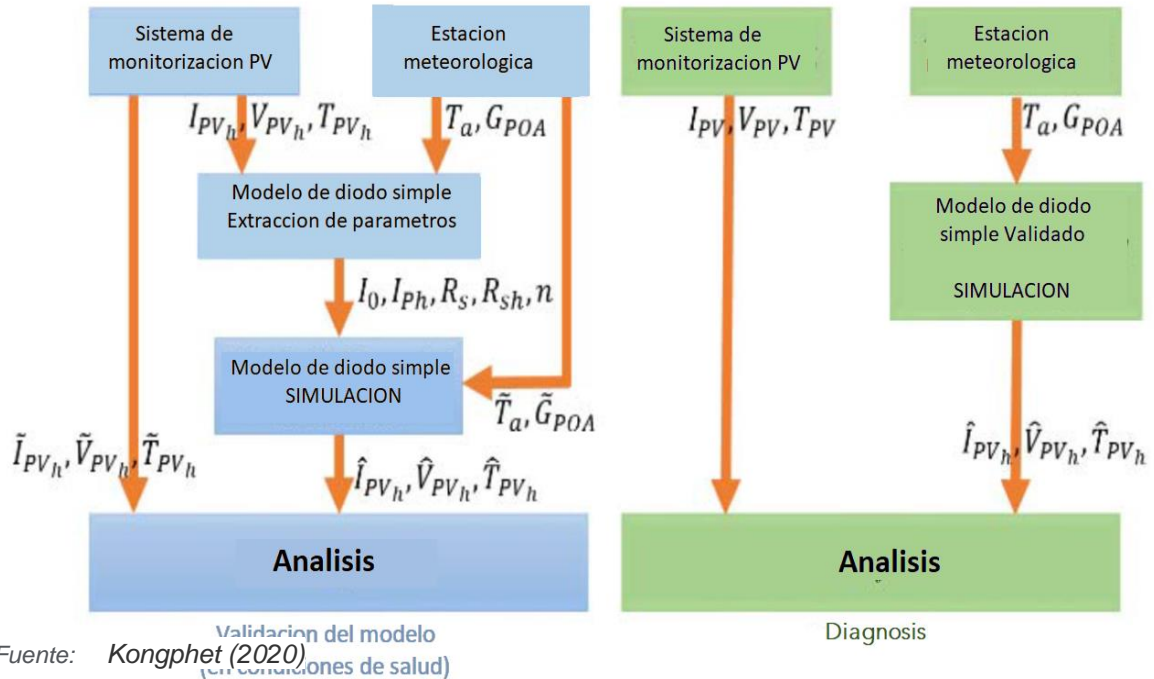
Caso de Uso 1 - Modelo de Diodo Único

Este caso se centra en la detección y el diagnóstico de fallas (fault detection and diagnosis, FDD) basada en el modelado físico fotovoltaico. En la siguiente figura,

- La parte derecha, en verde, representa las operaciones básicas de un sistema de monitoreo PHM, y
- La parte izquierda, en azul, los pasos preliminares obligatorios de configuración y validación del modelado.

El índice h identifica las variables relacionadas con la salud del activo, \sim marca las variables simples (inputs) y \wedge identifica las variables calculadas.

Figura 6: Detección de fallas y diagnóstico



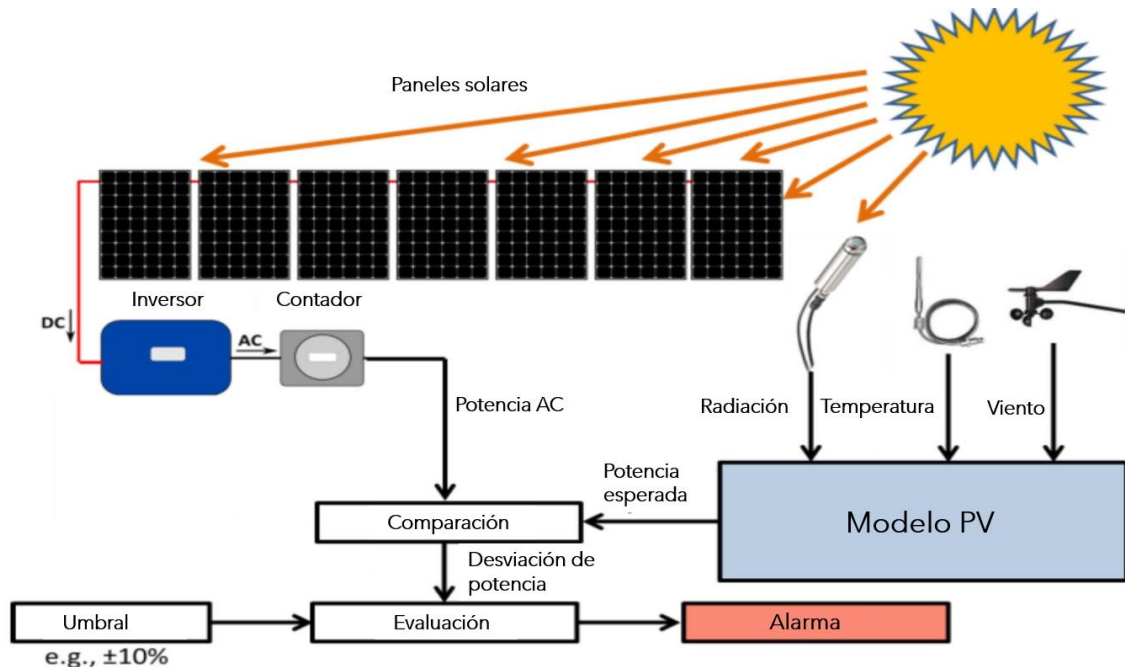
Las mediciones de capacitancia de tierra se pueden aplicar a una cadena fotovoltaica al aire libre para detectar fallas sin verse afectadas por cambios de irradiancia. La reflectometría de dominio temporal (time-domain reflectometry) es una técnica utilizada para localizar una degradación en una cadena PV. La monitorización en tiempo real y la FDD en sistemas fotovoltaicos utilizan la huella digital de las fallas, la que se basa en la comparación de los comportamientos reales del sistema y el modelo PHM en condiciones de tiempo real. Se utiliza un modelo de diodo único (Single Diode Model, SDM) con 5 parámetros, para modelar la característica de corriente-voltaje no lineal de un dispositivo fotovoltaico.

Para modelar un módulo fotovoltaico se puede considerar cada célula fotovoltaica o todo el módulo fotovoltaico o todos los niveles de granularidad entre esos dos. Las ecuaciones fundamentales se pueden utilizar después de haber sido adaptadas para cada caso. Los diferentes niveles de granularidad se utilizan en el proceso FDD, con el fin de detectar, identificar y localizar fallas en un módulo fotovoltaico.

Caso de Uso 2 – Detección de Fallas

En este caso un algoritmo PHM se probó en dos sistemas fotovoltaicos integrados en la Outdoor Test Facility (OTF) en el National Renewable Energy Laboratory (NREL). El algoritmo PV-PHM se entrenó utilizando dos meses de producción de potencia AC (AC power). El modelo predijo la potencia de salida utilizando datos de irradiancia, viento y temperatura. Sobre la base de la desviación en la potencia AC medida y la predicha, se detectaron interrupciones del sistema y otras fallas que causan reducción en la potencia solar. El PV-PHM puede indicar degradación, detectar fallas en el módulo o en el inversor, o detectar suciedad excesiva o iniciar una alerta de mantenimiento.

Figura 7: Modelo PV-PHM. Conectividad y flujo de información.



Fuente: Elaboración de los autores

En este caso el modelo PV-PHM utiliza una red neuronal artificial (Artificial Neural Net, ANN) que elimina la necesidad de información a priori al enseñar al algoritmo un comportamiento de "buen" rendimiento basado en el rendimiento teórico inicial. La ANN se compone de un simple perceptrón multicapa $4 \times 20 \times 1$, entrenado utilizando la metaheurística "particle swarm optimization".

Este proceso de entrenamiento de la RNA consiste en una adaptación progresiva de los valores de las conexiones sinápticas, para permitir a la RNA el aprendizaje de un comportamiento deseado. La implementación inicial del PV-PHM utilizó una red neuronal entrenada en dos meses y presentó que la varianza en la potencia AC predicha y la medida estaban altamente correlacionadas con las estaciones, es decir, la red neuronal se desempeñó mejor en las condiciones de temperatura en las que se entrenó. El método de detección de fallas de potencia AC es útil para detectar fallas a largo plazo que pueden reducir la producción del sistema fotovoltaico, como la degradación del material, la sombra de los árboles en crecimiento o la suciedad excesiva.

A.1.4. Almacenamiento de Energía de la Red


Un almacenamiento de energía (energy storage, ES) es una forma de almacenar electricidad para su consumo posterior a "gran escala" en una red de energía eléctrica. Esto debido a que hay períodos en los que las centrales eléctricas están en capacidad de producir energía más que suficiente para el consumo; lo que no se utiliza, se coloca temporalmente en un ES; a su vez, cuando el consumo supera la producción, los ESs se utilizan para suplir el déficit.

La digitalización ayuda a la gestión del almacenamiento de energía gracias a la optimización del flujo de energía entre la red y el sistema de almacenamiento.

En la cadena de abastecimiento de energía eléctrica, el sistema de almacenamiento de energía desempeña un papel esencial en el equilibrio entre la generación y la demanda. Además, del rendimiento a nivel de la red su efectividad se analiza en términos de los siguientes servicios:

- Regulación de frecuencias;
- Aplanamiento de la demanda máxima (peak shaving);
- Integración con fuentes de energía renovables; y
- Administración de energía.

Figura 8: Almacenamiento y entrega de energía en hora punta



Fuente: Mundo Eléctrico (2018)

A nivel del mercado eléctrico, la consecuencia directa de esto será el “aplanamiento” de la curva de costos marginales de generación de la energía con su correspondiente efecto en los precios. Según la Electricity Storage Association (ESA) se han desarrollado varios enfoques de almacenamiento de energía que se pueden clasificar en:

- Tecnologías de baterías secundarias.
- Baterías de flujo (CellCube).
- Supercondensadores.
- Volantes de inercia.
- Almacenamiento de energía de aire comprimido.
- Almacenamiento de energía térmica.
- Energía hidroeléctrica bombeada (pumping storage).


Lithium-Ion Battery

Una LIB es un tipo de batería recargable compuesta por celdas en las que los iones de litio se mueven desde el electrodo negativo, a través de un electrolito, hasta el electrodo positivo durante la descarga y viceversa durante la carga. Las celdas de iones de litio utilizan un compuesto de litio intercalado como material en el electrodo positivo y típicamente grafito en el electrodo negativo.

M. S. Whittingham descubrió el concepto de electrodos de intercalación en la década de 1970, e inventó la primera batería recargable de iones de litio, que se basó en un cátodo de disulfuro de

titanio y un ánodo de litio-aluminio, patentado en 1977, y asignado a Exxon. John Goodenough amplió este trabajo en 1980 mediante el uso de óxido de litio cobalto como cátodo. Las baterías de iones de litio se usan comúnmente para dispositivos electrónicos portátiles y vehículos eléctricos y están creciendo en popularidad para aplicaciones militares y aeroespaciales (Whittingham, 2019).

Figura 9: Esquema de una batería de ion de litio



Fuente: Mártil (2019)

Entre varias tecnologías de baterías, las LIBs exhiben una alta eficiencia energética, una larga vida útil y una densidad de energía relativamente alta. En esta perspectiva, se han analizado en detalle sus propiedades, incluido su mecanismo de operación, diseño y construcción, y ventajas y desventajas en los mercados de electricidad. Las LIBs no tienen efecto memoria (aparte de las celdas LFP, lithium ferro phosphate) y baja autodescarga; se pueden fabricar para priorizar la energía o la densidad de potencia. Sin embargo, pueden ser un peligro para la seguridad, ya que contienen electrolitos inflamables y, si están dañados o cargados incorrectamente, pueden provocar explosiones e incendios.

Las baterías recicladas incorrectamente pueden crear desechos contaminantes, especialmente de metales tóxicos y/o fácilmente inflamables. Además, tanto el litio como otros minerales estratégicos utilizados en las LIBs tienen problemas significativos en la extracción, ya que el litio consume: i) mucha agua en regiones a menudo áridas y ii) otros minerales que a menudo son minerales de conflicto como el cobalto. Ambos problemas ambientales han alentado a algunos investigadores a mejorar la eficiencia mineral y alternativas como las baterías de hierro-aire.

Las áreas de investigación para los LIB incluyen extender la vida útil, aumentar la densidad de energía, mejorar la seguridad, reducir los costos y aumentar la velocidad de carga, entre otros. Por otro lado, se han realizado investigaciones en el área de los electrolitos no inflamables como una vía para aumentar la seguridad basada en la inflamabilidad y la volatilidad de los disolventes orgánicos utilizados en el electrolito típico. Las estrategias incluyen baterías acuosas de iones de litio, electrolitos sólidos cerámicos, electrolitos de polímeros, líquidos iónicos y sistemas fuertemente fluorados.

La mayor demanda de las LIBs se encuentra en:

- Dispositivos portátiles: estos incluyen teléfonos móviles y teléfonos inteligentes, computadoras portátiles y tabletas, cámaras digitales y videocámaras, cigarrillos electrónicos, consolas de juegos portátiles y linternas.
- Herramientas eléctricas: incluyen herramientas inalámbricas como taladros, lijadoras, sierras y una variedad de equipos de jardín, incluidos látigos y corta setos.
- Vehículos eléctricos: se utilizan en vehículos eléctricos: automóviles, vehículos híbridos, motocicletas, scooters, bicicletas, transportadores personales, drones y sillas de ruedas.
- Estabilización de red eléctrica (balanceo de carga, regulación de frecuencia y tensión)


A.2. Mantenimiento de Subestaciones Eléctricas

Existen dos razones técnicas que explican por qué el transporte y la distribución en energía eléctrica se realiza a tensiones elevadas y, en consecuencia, por qué son necesarias las subestaciones eléctricas:

- Las pérdidas de potencia que se producen en un conductor por el que circula una corriente eléctrica, debido al efecto Joule, son directamente proporcionales al valor de esta ($P = I^2 \times R$).
- La potencia eléctrica transportada en una red es directamente proporcional al valor de su tensión y al de su intensidad ($P = V \times I$).

Por tanto, cuanto mayor sea el valor de la tensión, menor deberá ser el de intensidad para transmitir la misma potencia y, en consecuencia, menores serán las pérdidas por efecto Joule. El diagrama describe la conectividad de los múltiples tipos de subestaciones y/o de transformadores a lo largo de una red de transmisión/distribución de electricidad.

Figura 10: Esquema de conectividad de una red eléctrica



Fuente: Martín et al. (2019)

Una subestación eléctrica, subestación transformadora o subestación eléctrica transformadora (abreviadamente ST) es una instalación destinada a establecer los niveles de tensión adecuados para la transmisión y la distribución de la energía eléctrica. Su equipo principal es el transformador.

Además de transformadores, las ST están dotadas de elementos de maniobra (interruptores, seccionadores, etc.) y protección (fusibles, interruptores automáticos, etc.) que desempeñan un papel fundamental en los procesos de mantenimiento y de operación de las redes de distribución y transporte. Normalmente está dividida en secciones, por lo general tres principales (medición, cuchillas de paso e interruptor), y las demás son derivadas. Las secciones derivadas normalmente llevan interruptores de varios tipos hacia los transformadores.

Como norma general, se puede hablar de subestaciones eléctricas “elevadoras”, situadas en las inmediaciones de las centrales generadoras de energía eléctrica, cuya función es elevar el nivel de tensión antes de entregar la energía a la red de transporte; y subestaciones eléctricas “reductoras”, que reducen el nivel de tensión hasta valores que oscilan, habitualmente, entre 10 y los 66 kV y entregan la energía a la red de distribución. Posteriormente, los centros de transformación reducen los niveles de tensión hasta valores comerciales (baja tensión) aptos para el consumo doméstico e industrial.

Se denomina transformador a un elemento eléctrico que permite aumentar o disminuir la tensión en un circuito eléctrico de corriente alterna, manteniendo la potencia, basándose en el fenómeno de la inducción electromagnética. La potencia que ingresa al equipo, en el caso de un transformador ideal (esto es, sin pérdidas), es igual a la que se obtiene a la salida. Las máquinas reales presentan un pequeño porcentaje de pérdidas, dependiendo de su diseño, y de su tamaño, entre otros factores.

Está constituido por dos bobinas de material conductor, devanadas sobre un núcleo cerrado de material ferromagnético, pero aisladas entre sí eléctricamente. La única conexión entre las bobinas la constituye el flujo magnético común que se establece en el núcleo. El núcleo, generalmente, es fabricado bien sea de hierro o de láminas apiladas de acero eléctrico, aleación apropiada para optimizar el flujo magnético. Las bobinas o devanados se denominan primario y secundario según correspondan a la entrada o salida del sistema en cuestión, respectivamente. También existen transformadores con más devanados; en este caso, puede existir un devanado "terciario", de menor tensión que el secundario.

A.2.1. Análisis de Gases Disueltos

Las dos causas principales de la formación de gas dentro de un transformador en funcionamiento son las perturbaciones eléctricas y la descomposición térmica. Todos los transformadores generan gases hasta cierto punto a temperaturas normales de funcionamiento.

El análisis de gases disueltos (Dissolved Gas Analysis, DGA), es un examen de los contaminantes del aceite del transformador eléctrico. Esto debido a que los materiales aislantes dentro de los equipos eléctricos liberan gases a medida que se descomponen lentamente con el tiempo. La composición y la distribución de estos gases disueltos son indicadores de los efectos del deterioro, como el pirólisis o la descarga parcial, y la tasa de generación de gas indica la gravedad. El DGA es beneficioso para un programa de mantenimiento preventivo, consiste en muestrear el aceite y enviar la muestra a un laboratorio para su análisis. Las unidades móviles DGA también se pueden transportar y utilizar in situ; algunas unidades se pueden conectar directamente a un transformador. El monitoreo en línea de equipos eléctricos es una parte integral de la red inteligente.

Los módulos de software DGA analizan automáticamente las diferentes concentraciones y ofrece posibles problemas de causa-efecto junto con sugerencias correctivas. Para llegar a estos

hallazgos, se utilizan múltiples métodos, algunos de ellos son “Key Gas”, “Duval Triangle” o “Rogers Ratios”.

La tendencia actual es incorporar metodologías basadas en la analítica predictiva para mejorar las posibilidades de éxito de los análisis a partir de datos DGA.

A.2.2. PHM vía Red Neuronal Probabilística

El modelo utiliza sensores inteligentes para obtener datos DGA en el transformador. Se consideran dos casos de los encontrados en la literatura técnica.

Neural-Fuzzy Network


Una red neuronal difusa (neural-fuzzy network) es una máquina de aprendizaje que encuentra los parámetros de un sistema difuso (es decir, conjuntos difusos, reglas difusas) explotando técnicas de aproximación de redes neuronales.

Tanto las redes neuronales como los sistemas difusos tienen algunas cosas en común. Se pueden usar para resolver un problema (por ejemplo, reconocimiento de patrones, regresión o estimación de la función de densidad de probabilidad) si no existe ningún modelo matemático del problema. Sólo tienen ciertas desventajas y ventajas que desaparecen casi por completo al combinar ambos conceptos.

Las redes neuronales solo pueden entrar en juego si el problema se expresa mediante una cantidad suficiente de ejemplos observados. Estas observaciones se utilizan para entrenar la caja negra. Por un lado, no es necesario dar ningún conocimiento previo sobre el problema. Por otro lado, sin embargo, no es sencillo extraer reglas comprensibles de la estructura de la red neuronal. Por el contrario, un sistema difuso exige reglas lingüísticas en lugar de aprender ejemplos como conocimiento previo. Además, las variables de entrada y salida deben describirse lingüísticamente. Si el conocimiento es incompleto, incorrecto o contradictorio, entonces el sistema difuso debe ser sintonizado. Dado que no hay ningún enfoque formal para ello, la afinación se realiza de manera heurística. Esto suele llevar mucho tiempo y es propenso a errores.

En este caso, la arquitectura de la red NF (Neural-Fuzzy Network) consiste en cinco capas con tres capas ocultas. En cada una de las capas ocultas, hay seis y diez nodos para NF-MCS (Monte-Carlo Simulation) y NF-IS, respectivamente. En la capa de entradas, se consideraron 15 entradas que incluyen: furanos, H₂, CH₄, C₂H₄, C₂H₆, C₂H₂, CO, CO₂, humedad, ACBDV (AC breakdown voltage), DF, acidez, IFT, color y edad.

Figura 11: Arquitectura de la red NF



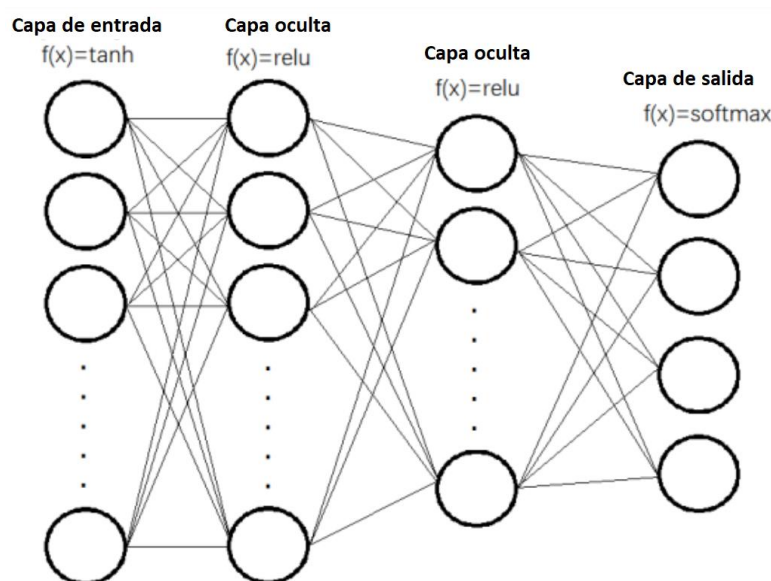
Fuente: Kadim et al. (2018)

El HI se obtuvo del método de puntuación para la comparación con el método NF. El HI de los transformadores que se obtuvo por NF entrenado por el método MCS está más cerca del método de puntuación que el NF entrenado por el método de evaluación de condición en servicio.

Red Neuronal Probabilística (PNN)

El “aprendizaje profundo” es comúnmente utilizado para determinar el tipo/causa de falla de los transformadores, utilizando como datos de entrada los resultados del DGA y como datos de salida una clasificación de fallas del transformador.

Figura 12: Deep Learning para el diagnóstico de fallos de un transformador de potencia



Fuente: MehdiPourPicha et al. (2019)

En este caso, se utiliza una red neuronal probabilística (Probabilistic Neural Net, PNN) como centro del proceso de forecasting del proceso PHM. Para estimar los pesos de la PNN, se adopta un algoritmo diferencial modificado de optimización basado en la “evolución de las ballenas jorobadas” (Modified Differential Evolution Whale Optimization Algorithm, MDE-WOA).

La PNN es una ANN feedforward, que se utiliza ampliamente en problemas de clasificación y reconocimiento de patrones. En el algoritmo PNN, la función de distribución de probabilidad padre (PDF) de cada clase se aproxima mediante una ventana de Parzen y una función no paramétrica. Luego, usando PDF de cada clase, se estima la probabilidad de clase de un nuevo dato de entrada y luego se emplea la regla de Bayes para asignar la clase con mayor probabilidad a-posteriori a los nuevos datos de entrada. Mediante este método, se minimiza la probabilidad de clasificación errónea. En una PNN las operaciones se organizan en una red feedforward multicapa con cuatro niveles:

- Input layer.
- Pattern layer.
- Summation layer.
- Output layer.

A.2.3. Algoritmo de Optimización de las Ballenas

Los algoritmos de optimización metaheurística se están volviendo cada vez más populares en las aplicaciones de ingeniería porque:

- Se basan en conceptos bastante simples y son fáciles de implementar.
- No requieren información de gradientes.
- Puede superar óptimos locales.
- Se puede utilizar en una amplia gama de problemas que cubren diferentes disciplinas.

Desafortunadamente, este tipo de algoritmos de optimización ignoran las matemáticas de la optimización, se soportan en criterios lógicos imitando en muchos casos procesos inteligentes, pero que no pueden ser clasificados como óptimos.

Whale Optimization Algorithm (WOA) es un algoritmo de optimización metaheurística inspirado en la naturaleza que imita el comportamiento de caza de las ballenas jorobadas. El algoritmo está inspirado en la estrategia de caza de redes de burbujas.

El comportamiento de “forrajeo” de las ballenas jorobadas se llama método de alimentación de red de burbujas (bubble-net feeding). Las ballenas jorobadas prefieren cazar bancos de peces pequeños cerca de la superficie. Se ha observado que este forrajeo se realiza mediante la creación de burbujas distintivas a lo largo de un círculo o camino en forma de 9.

A.2.4. Caso Power Supply Company

En términos del efecto de la capacidad del modelo de transformador, la humedad ambiental y la temperatura en el rendimiento del transformador, se recopilan los datos de gas del aceite de transformadores reales de compañías de suministro de energía (Power Supply Company, PSC) en la provincia de Jiangxi, China, en 2019. El transformador de potencia estudiado es del tipo de gas disuelto en aceite.

Como muestras de datos históricos se obtuvieron 555 muestras de contenido de gas, así:

- 65 casos de descarga parcial (PD).

- 361 casos de sobrecalentamiento a baja temperatura (LT) ($<150^{\circ}\text{C}$).
- 40 casos de sobrecalentamiento a baja temperatura (LT) ($150^{\circ}\text{C} - 300^{\circ}\text{C}$).
- 89 casos de descarga de arco (AD).

Para estas muestras, se utilizaron 400 datos como conjunto de entrenamiento y los datos restantes se utilizaron como conjunto de pruebas (verificación).

De acuerdo con la relación del contenido de gas disuelto en el aceite del transformador, con el método DGA se puede obtener el tipo de falla correspondiente.

TH es el hidrocarburo total del aceite del transformador y durante el experimento, la temperatura normal de funcionamiento es de 25°C y la humedad de fraguado es del 50%.

Se implementó un modelo PHM utilizando PNN-MDE-WOA lo que mejoró significativamente la convergencia global de la red PNN al salir rápidamente de una solución óptima local a una global. Para evaluar la efectividad del MDE-WOA, se comparó la precisión de clasificación del método con cuatro métodos (BA-BP, CS-BP, GA-BP y PNN) utilizando MATLAB para experimentos de simulación. La tabla muestra la precisión de la detección y la predicción de fallas; el modelo MDE-WOA fue el mejor entre todos los modelos de diagnóstico. BA-BP significa optimized by Bat algorithm (BA). CS-BP significa optimized by Cuckoo search (CS) algorithm. GA-BP significa optimized by Genetic algorithm (GA)

Figura 13: Ranking comparativo de modelos de detección y predicción de fallas

Ranking	Metodo	Exito	LT ($<150^{\circ}\text{C}$)	LT $150^{\circ}\text{C}-300^{\circ}\text{C}$	PD	AD
		Precision %	Precision %	Precision %	Precision %	Precision %
1	MDE-WOA	98.86	100	100	100	95.46
2	BA-BP	96.7	99.06	92.31	100	95.45
3	CS-BP	96.31	94.34	100	100	90.91
4	GA-BP	93.3	99.06	92.31	100	81.82
5	PNN	84.58	100	100	42.86	95.45

Fuente: Zhang et al. (2020)

Con datos del mundo real del sensor del transformador de potencia en la provincia de Jiangxi, China. Los resultados indicaron que el algoritmo propuesto podría lograr la mayor precisión diagnóstica en la cuarta iteración, habiendo alcanzado su precisión el 98,86%.

A.3. Mantenimiento Integral de Sistemas de Generación de Electricidad

A.3.1. Optimización bajo Incertidumbre

Si bien hace varias décadas resolver problemas de optimización estocástica de gran tamaño utilizando gran cantidad de escenarios parecía inalcanzable, los avances tecnológicos en todas las direcciones (velocidad del procesador, capacidad de memoria caché y memoria RAM, velocidad de los "solvers", redes de comunicaciones de alta velocidad,...) hicieron de la optimización estocástica una metodología viable para enfrentar el problema del manejo de la incertidumbre en el proceso de toma de decisiones, llevándola a la cima de las metodologías analíticas en lo que se refiere a la productividad/competitividad aportada y a la complejidad manejada.

A.3.2. Mantenimiento en Plantas Industriales Eléctricas

A continuación, se analiza la planificación integrada de múltiples activos industriales y de las actividades de producción que se deben llevar a cabo para cumplir con los compromisos de atención de la demanda que normalmente tienen los complejos industriales (integrados por activos industriales ubicados en múltiples sitios de producción). El proceso de mantenimiento, ejecutado periódicamente, debe proporcionar una operación segura y confiable para mejorar aspectos operativos relevantes tales como funcionalidad, seguridad y productividad de las plantas.

Conceptualización

Existen dos enfoques básicos para planificar óptimamente actividades de mantenimiento de infraestructura industrial de gran tamaño (centrales de generación, cadenas hidráulicas, plantas industriales, líneas de producción, unidades de proceso, ...) la cual se debe modelar como el mantenimiento de toda la infraestructura en medio de un modelo del tipo S&OP (Sales & Operations Planning) orientado a la planificación de la producción.

En el primer enfoque se utiliza un manejo discreto del intervalo de tiempo, dividiendo el horizonte de planificación en múltiples períodos y se asignan las actividades de mantenimiento a uno u otro período, bajo la hipótesis de que la duración de las actividades de mantenimiento es un múltiplo de la longitud básica que se haya seleccionado.

Existe un enfoque alternativo, en el cual el tiempo se maneja de forma continua por medio de variables asociadas a los instantes en que comienza y en que termina una determinada actividad. Bajo esta concepción es posible modelar el “scheduling” de complejos procesos industriales. Sin embargo, este enfoque más preciso en el manejo del tiempo que el primero, requiere de un mayor esfuerzo de modelaje y no se utiliza en el modelo que se propone, por esta razón se deja de lado en el análisis que se realiza en el presente documento.

Con respecto al modelamiento convencional de planeamiento operativo, el modelaje de mantenimiento implica convertir las disponibilidades de las plantas/líneas/unidades/... en variables derivadas de las decisiones asociadas al mantenimiento. Las restricciones que debe incluir el modelaje incluyen las de consumo de recursos y los períodos, ventanas de tiempo, en los cuales se deben realizar los mantenimientos.

La optimización de mantenimiento tiene como objetivo programar los mantenimientos de forma tal de maximizar los ingresos debidos a las asignaciones de mantenimiento. Por lo tanto, la optimización del mantenimiento se realiza teniendo en cuenta los compromisos y las oportunidades en los mercados en que se negocian los productos de la empresa (en este caso la electricidad), teniendo como referencia las variables del entorno de decisiones (precios y cantidades de materias primas y/o de productos finales), si estas variables son aleatorias, se deberán incorporar en el modelo las predicciones convirtiendo el modelo en uno de programación estocástica.

La mayor complejidad que se prevé para modelar las decisiones de mantenimiento es la relación entre los costos marginales (beneficio marginales o costos de oportunidad) de corto plazo que definen el valor de los productos en un momento dado y los mantenimientos, ya que, para una empresa con poder dominante, las decisiones de mantenimiento pueden producir un alza en el costo marginal por razones de menor disponibilidad en todo el sistema.

Por lo tanto, el modelo de optimización del mantenimiento debe vincularse con el modelo de producción (típicamente un S&OP) de forma tal de relacionar mantenimientos y capacidad

productiva. Si se considera la incertidumbre en los parámetros del entorno, el modelo puede ser del tipo de optimización estocástica no-anticipativa de dos etapas; en la primera se toman las decisiones asociadas al mantenimiento de los activos industriales (unidades de generación, embalses) y en la segunda se simulan las operaciones y los ingresos/egresos, asociados a diferentes escenarios de los factores relacionados con la incertidumbre.

Modelamiento Matemático de Optimización

Lo apropiado es utilizar modelos de programación estocástica mixta (normalmente se requiere de variables binarias para representar el parado de plantas (líneas/unidades/celdas) de producción, los más simples serán los modelos de dos etapas. En la primera etapa se fijan las decisiones de mantenimiento y en la segunda se estima el costo de la operación presente y futura, dependiente de las decisiones de mantenimiento. El modelamiento detallado depende del caso específico y puede requerir más o menos ecuaciones.

A.3.3. Empresa Generadora de Electricidad

Con respecto al modelamiento convencional de planeamiento operativo de un sistema de generación de electricidad, el modelaje de mantenimiento implica el convertir las disponibilidades de las plantas de generación (de cualquier tipo) en variables derivadas de las decisiones asociadas al mantenimiento. Las restricciones que debe incluir el modelaje incluyen las de consumo de recursos, y los períodos, ventanas de tiempo, en los cuales se deben realizar los mantenimientos.

La optimización tiene como objetivo programar los mantenimientos de forma tal de maximizar los ingresos debidos, para ello se debe tener en cuenta:

- La energía comprometida en el mercado de largo plazo,
- Las predicciones del precio en el mercado spot,
- Las asignaciones de energía firme asignadas o vendidas y
- Cualquier cargo que afecte los ingresos/egresos del generador.

Para asignar las actividades de mantenimiento a uno u a otro período, se reduce la capacidad de producción de los períodos en que se haga mantenimiento de acuerdo con la magnitud de este. Esta pérdida de capacidad puede ser total, si implica una parada de la planta, o parcial, si implica paradas parciales o pérdida de potencia de generación debida a las actividades del mantenimiento.

En el caso de mercados oligopólicos, como el mercado eléctrico, la mayor complejidad que se prevé para modelar las decisiones de mantenimiento es la relación entre los costos marginales de corto plazo, referencia para el valor de la energía en el mercado spot, y los mantenimientos, ya que las decisiones de mantenimiento pueden producir un alza en el costo marginal por razones de menor disponibilidad en todo el sistema; sin embargo, en este ejemplo se asume que debido al tamaño del sistema de generación no se espera que mantenimientos en las plantas del generador altere los precios del mercado spot.

La concepción del modelaje está basada en la utilización de dos modelos, un modelo de despacho del sistema eléctrico (DISPATCH) que proporciona el valor de los costos marginales como un proxy de los precios spot, que son utilizados en el modelo de optimización del mantenimiento (OPT-MAN) que evalúa los ingresos esperados derivados de las decisiones asociadas al mantenimiento. Para efectos del modelo de optimización del mantenimiento de unidades de generación y de almacenamientos y trasvases se deben tener en cuenta dos aspectos: incertidumbre y el proceso de mantenimientos.

En cada caso se debe determinar el impacto en la capacidad productiva derivado del mantenimiento, el cual es diferente para cada elemento:

- Unidades de generación: El efecto derivado del mantenimiento de una unidad térmica se resume en la indisponibilidad total de la unidad de generación que está en mantenimiento.
- Almacenamientos (embalses/tanques/pondajes): El efecto derivado del mantenimiento de un almacenamiento se resume en la pérdida de la capacidad de almacenar recurso hídrico durante todo el período que dura el mantenimiento.

Puede existir interacción entre los mantenimientos de elementos de diferente tipo. Esto se debe a relaciones vinculantes entre los diferentes elementos y a la posibilidad de consumo de recursos comunes en los procesos de mantenimiento. Por ejemplo, en el primer caso puede darse que para coordinar el mantenimiento de un almacenamiento sea necesario detener unidades de generación dependientes del almacenamiento.

La función de ingresos se personaliza de acuerdo con la situación del agente, para este caso (un generador en Colombia) se tiene la siguiente ecuación que define los ingresos operacionales:

$$\begin{aligned} & \text{Generación Hidráulica} \times \text{Precio SPOT} \\ & + \text{Ingresos por Venta Electricidad} - \text{Egresos Compra Electricidad} \\ & + \text{Ingresos por OEF} - \text{Egresos por OEF} \\ & - \text{Costo de Recurso} \times \text{Cantidad Recurso utilizado en Mantenimientos} \end{aligned}$$

Estos costos pueden, o no, depender del período, como es el caso de recurso de mano de obra que en días hábiles tiene menos costos que días festivos. OEF se refiere a las Obligaciones de Energía en Firme (propias del mercado colombiano).

A.3.4. Sistema Interconectado

Se entiende por planificación holística la planificación integrada de las instalaciones mayores del sistema eléctrico, estas pueden ser:

- Centrales y/o unidades de generación.
- Almacenamientos de energía (“energy storages”).
- Canales de conducción.
- Embalses y/o presas.
- Líneas de transmisión.
- Subestaciones del sistema de transmisión.

Para analizar lo anterior se puede generar un modelo que integre el despacho económico (o cualquier modificación de este) con el modelo de mantenimiento (ecuaciones que representan el proceso de mantenimiento para cada tipo de instalación). El objetivo de la operación será maximizar el excedente social, que para sistemas eléctricos en los que se asume la demanda inelástica corresponde a minimizar los costos de funcionamiento.

A.3.5. Implementación Computacional

La implementación de modelos matemáticos de optimización involucra tecnologías libres y comerciales que no siempre son conocidas por los científicos de datos que trabajan en analítica predictiva. De acuerdo con las tecnologías informáticas actuales, al menos cuatro tecnologías de

optimización están involucradas en el proceso de desarrollo de un modelo matemático complejo, se describen a continuación:

Figura 14: Tecnologías de Optimización



Fuente: Elaboración de los autores

- **Optimization Solvers.** Son productos altamente especializados basados en las leyes matemáticas de la optimización. Son la base de toda optimización matemática de alta complejidad. Para acelerar su rendimiento (tiempo para resolver problemas matemáticos), se implementan metodologías de optimización a gran escala.
- **Programming Language.** Productos orientados al desarrollo de modelos de optimización, enfocados a proporcionar al modelador matemático un medio para implementar algoritmos especializados en ciertos tipos de problemas matemáticos (lineales, no lineales, ...). Los lenguajes computacionales se comunican con los solucionadores para resolver problemas. Las metodologías a gran escala se implementan en este nivel.
- **Optimization Informatic Platform.** Plataformas informáticas que integran todos los aspectos informáticos necesarios para la implantación de los Sistemas de Apoyo a la Decisión (DSS). Facilitan la puesta en marcha (despliegue) y el mantenimiento de los DSS para una organización, integrando múltiples modelos matemáticos, bases de datos e interfaces de visualización.
- **Optimization Expert Systems.** Sistemas expertos y robots cognitivos que generan algoritmos en múltiples tecnologías de optimización para múltiples modelos matemáticos, simplificando el proceso de implementación de soluciones complejas e integradas. Los sistemas expertos almacenan información sobre los modelos desarrollados y las corridas realizadas con estos modelos y mejoran el conocimiento del modelador matemático, ya que asume la responsabilidad de todas las tareas sistemáticas y repetitivas, lo que implica la implementación de múltiples modelos matemáticos que deben coordinarse entre sí.

A.3.6. Modelamiento del Riesgo

Los modelos de optimización estocástica permiten incluir consideraciones sobre el manejo de riesgo; específicamente se pueden resolver los problemas con base en la optimización del valor esperado de la función objetivo, restringiendo una medida cuantificable (objetiva) de los riesgos asumidos, ya sean financieros u operacionales. Si bien en este caso un modelo matemático de optimización no puede seleccionar una decisión como la “mejor”, la única óptima, pueden ayudar al decisor a construir curvas Pareto eficientes para análisis multicriterio: ingreso esperado versus riesgo asumido.

Existen varias medidas del riesgo asociado a una decisión, entre ellas se pueden enumerar:

- La varianza de la medida de rendimiento.
- El valor en riesgo (VaR, Value-at-Risk) o la utilidad en riesgo (PaR, Profit-at-Risk).
- El exceso de pérdida esperado, o valor en riesgo condicionado (CVaR), o las ganancias en riesgo condicionadas (CPaR).

Cualquiera de estas medidas de riesgo puede incluirse y controlarse en un modelo de optimización estocástica. Sin embargo, la más utilizada actualmente es el CVaR, por su carácter lineal fácil de introducir en los modelos matemáticos de optimización.

A.4. Sistemas Aéreos No-Tripulados para Servicios Públicos de Energía

En los últimos años, los UASs (Unmanned Aerial Systems) han sido vistos como una nueva herramienta inteligente en muchas industrias, incluida la gestión pública, el rescate de emergencias, la energía, la agricultura, el transporte y el levantamiento espacial, etc. Estas herramientas inteligentes han ampliado las capacidades de las personas, las han mantenido alejadas del peligro y han mejorado la eficiencia del trabajo.

Los sistemas UAS, como las flotas (enjambres) de drones, se utilizan cada vez más para automatizar la planificación, la construcción y el mantenimiento de las instalaciones de energía en todo el mundo. La efectividad de los UAS y las tecnologías digitales están transformando las operaciones del sector energético para que sean más rápidas, seguras y rentables.

A.4.1. Metodologías

Dos metodologías matemáticas son importantes en el uso de UASs:

- Procesamiento de imágenes, y
- Ruteo de vehículos.

Procesamiento de Imágenes

Las redes neuronales profundas Deep Neural Networks (DNNs) trajeron importantes avances para el procesamiento de imágenes, lenguaje natural, audio, video y muchas otras aplicaciones de reconocimiento de patrones. En el campo de la teleobservación, los algoritmos DNN en aplicaciones basadas en vehículos aéreos no tripulados (UAV) están dominando la investigación. El Deep Learning (DL) presenta resultados para procesar tareas asociadas con datos de imágenes basados en UAV en diversos campos de la teledetección, agrupándolos en los contextos ambientales, industriales, urbanos y agrícolas.

Deep Neural Networks

Las Deep Neural Network (DNN) se basan en redes neuronales que se componen de neuronas con cierta activación y parámetros que transforman los datos de entrada (por ejemplo, la imagen de teledetección de UAV) en salidas (por ejemplo, mapas de uso de la tierra y cobertura terrestre) mientras aprenden progresivamente características de nivel superior (Ma et al., 2019). Este aprendizaje progresivo de características ocurre, entre otros, en capas entre la entrada y la salida, que se conocen como capas ocultas (Ma et al.).

Una arquitectura DNN se puede construir a partir de una capa inicial (Xinput) que se compone de las muestras de datos recopiladas. Más tarde, esta información de datos puede ser extraída por capas ocultas de una manera de retro-propagación (backpropagation) que es utilizada por las capas ocultas posteriores para aprender las características de estas entidades. Al final, se utiliza otra capa con una función de activación relacionada con el problema dado, devolviendo un resultado de predicción (Ylabel).

Una DNN puede estar formada por diferentes arquitecturas, y la complejidad del modelo está relacionada con la forma en que se implementa cada capa. Regularmente se proponen diferentes arquitecturas DL:

- Redes Neuronales Convolucionales (Convolutional Neural Networks, CNN),
- Redes Neuronales Recurrentes (Recurrent Neural Networks, RNN),
- Redes de Creencias Profundas (Deep Belief Networks, DBN) (Ball et al.) y, más recientemente,
- Redes Generativas Adversariales (Generative Adversarial Networks, GAN, Goodfellow et al., 2016).

Para el procesamiento de imágenes y reconocimiento de objetos/patrones, la mayoría de la investigación actual se centra en las CNN, desde que en 2012 demostraron un método que ganó un concurso de clasificación de imágenes por un gran margen a su favor (Krizhevsky et al., 2012).

A.4.2. Casos de Uso

En los próximos años los operadores de redes eléctricas operarán y mantendrán una base de activos cada vez mayor. La inspección de redes eléctricas utilizando UAVs (Unmanned Aerial Vehicles) se presenta como una de las mejores opciones teniendo en cuenta que la relación costo-beneficio es mayor en comparación con los otros métodos, ya que presenta: i) menor costo, ii) precisión, iii) eficiencia y iv) seguridad. Estas plataformas están equipadas con sensores de última generación, como sensores y cámaras de detección y alcance de luz (Light Detection and Ranging, LIDAR) (por ejemplo, video, foto y visión térmica) que se pueden usar para navegar a lo largo de redes eléctricas y recopilar imágenes y datos en tiempo real. Además, los UAV pueden estar cerca de las redes eléctricas mejorando significativamente la precisión de la inspección, tomando información más detallada de los conductores, torres y componentes del sistema de potencia.

El uso de UAVs para realizar inspecciones de redes eléctricas permite disminuir los costos del mantenimiento y de la operación del sistema de energía. También permite actuar en una ventana de tiempo corta sin restricciones, con menos limitaciones debidas al clima y las autorizaciones locales. Es un paso enorme para facilitar a los operadores la gestión de redes eléctricas.

A.4.3. VRP: Vehicle Routing Problem with RUL Control

A continuación, se presenta la formulación del problema de ruteo de una flota de drones que debe tener en cuenta en la asignación de la ruta el RUL de cada dron, de forma tal de garantizar que

cada dron pueda retornar a la base sin sufrir una falla en el vuelo. Este podría ser el caso de programar visitas de los drones a sitios que deben ser inspeccionados en un turno/período de trabajo.

Para planificar las rutas se utiliza un modelo de optimización estocástica por escenarios (subíndice h) en el que se han generado valores sintéticos del $RUL_{v,h}$ para cada vehículo v.

A.4.4. Inspección Visual de Líneas Eléctricas

Malveiro et al. (2015) presentaron el sistema del CME (Portugal) para inspección de líneas eléctricas de alta tensión utilizando UAVs, que ofrece los siguientes servicios:

- Inspección visual de líneas eléctricas aéreas (video e imágenes);
- Inspección térmica de líneas eléctricas aéreas;
- Mapeo de corredores de líneas eléctricas aéreas y DTM (Digital Terrain Model);
- Informes de solución de problemas;
- Servicios de datos LIDAR y GIS;
- Vegetación bajo control de líneas eléctricas e informes de mantenimiento.

Los activos observados pueden ser los siguientes:

- Cimentaciones de postes;
- Señalización y seguridad;
- Puesta a tierra;
- Condiciones de los postes;
- Aisladores;
- Conductores;
- Equipos de protección;
- Equipo de maniobra;
- Transiciones subterráneas;
- Protecciones para los animales;
- Cable OPGW;
- Grupos de conductores;
- Línea anti vibradores;
- Cruce de líneas eléctricas aéreas;
- Distancias de las líneas eléctricas aéreas;
- Control de la vegetación;
- Subestaciones;
- Termal

Después de recopilar y analizar los datos se puede estimar una ventana de tiempo para realizar cualquier cambio necesario en la línea eléctrica y/o en los accesorios. Estas acciones se pueden clasificar en un nivel de criticidad.

- Nivel 4 – Alto riesgo – Es necesario tomar medidas en un período de tiempo muy corto;
- Nivel 3 – Riesgo moderado – Se deben tomar medidas en una ventana de tiempo de corto plazo;
- Nivel 2 – Bajo riesgo – Es necesario tomar medidas en el mediano plazo;
- Nivel 1 – Riesgo muy bajo – Las acciones se pueden realizar en el largo plazo. No es urgente.

Sistemas de UAVs Cooperativos

Los sistemas UAV trabajando cooperativamente utilizan tres tipos de UAV: la inspección incompleta a larga distancia, la inspección más cercana a corta distancia y el relé de comunicaciones. Tres tipos de UAV proveen la funcionalidad para una operación cooperativa que puede ampliar en gran medida el rango de inspección y mejorar la calidad de la inspección:

- Fixed Wing UAV
- HexRotor UAV
- Tethered Multi-rotor UAV

Después de la inspección incompleta del UAV de ala fija, se identifican y localizan los defectos de las líneas de transmisión de energía. A continuación, se utiliza un UAV hexrotor para una inspección adicional para el registro de detalles. El tethered multi-rotor UAV sirve como una plataforma en el aire. Consiste en pequeños 4 rotores en un plano y un gran rotor sobre él, impulsado por motores eléctricos. El rotor grande representa la mayor fuerza de elevación y los cuatro pequeños representan el control del equilibrio. El cable conectado directamente al motor eléctrico del UAV puede flotar en el aire durante un tiempo “infinito”. La capacidad de carga es mucho más grande que el hexrotor lo que permite que este UAV lleve más carga útil para múltiples funcionalidades.

El UAV multi-rotor lleva el módulo de comunicación para el relé de señal entre los UAVs y la estación terrestre. Esto es necesario porque en muchos entornos la ruta de transmisión de la señal entre la aeronave y la estación terrestre no está en una línea de visión, lo que lleva a una falla de comunicación, el UAV se utiliza las comunicaciones de línea de visión no son factibles.

Un equipo de inspección típico de UAV consta de seis personas, incluidos expertos en el campo de las operaciones, transportes y comunicaciones que está equipado con 4 a 5 UAVs, incluyendo 1 ala fija, 3 hexrotores y 1 multi-rotor. Primero se utiliza el UAV de ala fija para obtener la condición general a lo largo de la línea de transmisión. Los videos/imágenes en tiempo real se transmiten a través del enlace de datos a la estación terrestre. Estos videos se transmiten a través de la comunicación satelital a la oficina administrativa de operaciones para un análisis rápido y toma de decisiones de inspección adicionales. Los especialistas en el back office identificarán la torre o línea de transmisión específica que se inspeccionará más a fondo. Una vez que se realiza la tarea de inspección específica, la tripulación en el sitio llevará el UAV hexrotor al área designada para una inspección más detallada. La tripulación puede enviar múltiples hexrotores para diferentes sitios a la vez. Los videos detallados de los UAV hexrotores también se transmiten al back office para su análisis en tiempo real.

Reglamentación

En los países industrializados, las empresas de servicios públicos de energía han sido autorizadas a usar drones para inspecciones durante años. San Diego Gas & Electric recibió permiso de uso de la Administración Federal de Aviación de los Estados Unidos (FAA) (Informed Infrastructure, 2014). Sin embargo, estas aplicaciones se limitan principalmente a volar dentro de la línea visual de visión (VLOS, Visual Line of Sight). El mayor valor de los drones en las inspecciones radica en el crucero automático a lo largo del derecho de paso más allá de la línea visual de visión (BVLOS, Beyond the Visual Line of Sight). La FAA requiere que un dron permanezca dentro del VLOS del piloto durante todo el vuelo. Muchas otras naciones siguieron lo mismo debido a preocupaciones de seguridad.

La inspección de las instalaciones de energía es para garantizar la seguridad de los suministros de energía para el público. Realizar el vuelo BVLOS maximizará el beneficio, y es necesario en situación de emergencia. El tiempo de vuelo y la ruta se pueden planificar, etiquetar y registrar con anticipación con los datos puestos a disposición del regulador. En algunos países como el Reino Unido, Polonia y China, las empresas de servicios públicos pueden obtener una exención especial para realizar vuelos BVLOS. Los organismos de control europeos también han otorgado permisos especiales para permitir que las empresas de servicios públicos prueben prototipos. La Agencia de Seguridad Aérea de la Unión Europea (AESA) también racionalizará los procedimientos y otorgará autorizaciones para las operaciones específicas. BVLOS será el próximo impulsor de la expansión de la operación de drones.

A.4.5. Inspección Rutinaria de Líneas y Torres

Las inspecciones rutinarias de líneas y torres son un mantenimiento preventivo orientado a los detalles. La inspección se llevó a cabo sobre una base de torre, lo que requiere una mayor precisión para los pernos y pasadores. Los UAV de ala multi-rotor pequeños o medianos son los más utilizados, llevando cámaras visibles e infrarrojas. Aproximadamente en 1 hora de tiempo de vuelo se pueden completar inspecciones de dos a tres torres de alto voltaje. En algunas soluciones, los drones se controlan manualmente a través de pantallas o mediante realidad virtual.

Las operaciones manuales a veces están limitadas por las condiciones climáticas, la distancia y las capacidades del operador. Actualmente, los drones de piloto automático se han desarrollado para inspecciones de torres y se han vuelto más populares. Como el diseño de las torres de transmisión a menudo está estandarizado, los tipos de torre se limitan a docenas a un nivel de voltaje. La ruta de vuelo automática se puede predefinir en consecuencia. Las coordenadas de la ruta se establecen para dar al UAV la mejor posición para tomar la foto a una distancia segura. Los operadores simplemente seleccionan y confirman el tipo de torre objetivo antes de despegar.

Figura 15: Inspección de líneas aéreas con drones



Fuente: Aerialtronics (2022)

A.4.6. Inspección del Corredor de Línea

Las inspecciones de corredores de línea son generalmente escaneo de accidentes geográficos y medición del objeto debajo o líneas eléctricas cercanas para identificar el riesgo y el peligro potencial. En general, la inspección del corredor incluye escaneo rápido (un examen rápido del corredor de línea en busca de riesgos potenciales externos importantes con luz visible y cámara infrarroja) y mapeo detallado.

El escaneo busca:

- Objetos extraños en el cable o la torre, como plástico, bolsas y cometas,
- Examina la vegetación, edificios o sitios de construcción inesperados, etc.

Los drones de ala fija tienen ventajas inherentes que ofrecen velocidades de vuelo más rápidas con un rango más amplio, su diseño compacto hace que sea más portátil y silencioso.

Figura 16: Inspección de corredor de línea eléctrica



Fuente: Enterprise (2022)

Las inspecciones de corredores de línea escanean y miden objetos debajo o en las líneas eléctricas cercanas, lo que implica un escaneo rápido y un mapeo detallado.

El mapeo detallado aplica LiDAR (Light Detection and Ranging) para obtener datos tridimensionales (3D) de las torres, líneas y entorno de corredores. Los datos geológicos se registran y se puede construir un modelo digital 3D para toda la línea eléctrica con toda la invasión de vegetación, el edificio y los alrededores.

Esto es muy útil cuando las instalaciones se encuentran en lugares montañosos o regiones propensas a desastres. El modelo establece la línea base para la supervisión, las operaciones y la planificación. El usuario puede analizar el crecimiento de la vegetación y simular el impacto de eventos climáticos extremos como fuertes vientos, inundaciones, cobertura de hielo y temperaturas altas/bajas. Permite la predicción de amenazas futuras con muchas variables imprevistas.

Figura 17: Inspección de corredor de línea eléctrica



Fuente: Quaternium (2022)

A.4.7. Gestión de Emergencias

En caso de emergencias como terremotos, deslizamientos de tierra o incendios forestales, el área afectada puede no ser accesible. Los equipos de O&M perderían el mejor momento para rescatar. UAS puede realizar una inspección posterior al desastre y una encuesta de impacto. Con la imagen, el equipo de mantenimiento podría evaluar primero el daño y priorizar las operaciones y la distribución de los recursos. Los datos también ayudarían a los despachadores de la red a tomar medidas rápidas para restaurar la energía. Todo el proceso de reparación y recuperación se puede acelerar. Los drones equipados con láseres, pistolas de fuego o cables eléctricos se pueden usar para limpiar objetos colgantes en instalaciones, como cometas, globos, bolsas de plástico, etc.

En caso de falla de energía, el programa de ubicación de fallas en el sistema de energía no puede proporcionar la posición precisa. Los resultados de la ubicación se desvían de medio a varios kilómetros. A menudo le cuesta mucho tiempo al equipo de mantenimiento encontrar la falla. UAS puede acelerar el proceso de búsqueda de fallas.

Tecnologías Clave

- Piloto automático.
- Identificación de fallas y procesamiento de lotes.
- Soluciones de piloto automático de larga distancia.
- Aplicaciones en proyectos de energía limpia.
- Otras aplicaciones en el sector energético.

B. Guía de implementación de un Sistema PHM

B.1. Fases de un PHM

La digitalización es un motor fundamental de la I4.0, un paradigma que mejora la eficiencia de la producción a través de las tecnologías de la información y de la comunicación. Estas tecnologías proporcionan la base para el mantenimiento predictivo de componentes de los sistemas industriales eléctricos, mediante el cual los datos de monitoreo de la condición del activo se emplean para realizar cuatro tareas:

- a) Detección de estados anormales, mediante la identificación de desviaciones de las condiciones normales de: i) operación en los procesos de producción, ii) operación en equipos de fabricación y iii) calidad de los productos;
- b) Diagnósticos, mediante la clasificación de estados anormales;
- c) Pronósticos, mediante la predicción de la evolución de estados anormales hasta la falla;
- d) Optimización de las decisiones relacionadas con el mantenimiento de los activos.

La detección, el diagnóstico, el pronóstico y la optimización constituyen el ciclo de PHM que soluciona el problema de mantenimiento en cuatro pasos:

1. Observación (adquisición de datos).
2. Procesamiento de datos.
3. Análisis predictivo.
4. Análisis prescriptivo.
5. Acción de implementación de las decisiones.

Las actividades a realizar en cada paso son:

1. Observación (Adquisición de datos)

corresponde a un proceso de recopilación y almacenamiento de los datos de un componente para fines de diagnóstico y de pronóstico. Los datos son mediciones obtenidas a través de sensores de: i) múltiples variables, por ejemplo, emisión acústica, vibración, temperatura, presión, humedad, resistencia, voltaje, etc.; o de ii) eventos, por ejemplo, avería, limpieza, engrase, etc. Para que se resuelva cualquier problema predictivo en el mantenimiento, la disponibilidad de datos es de suma importancia. Los dispositivos IoT y los sensores inteligentes se utilizan normalmente para adquirir datos en entornos de fabricación. Los datos se registran y evalúan en tiempo real, ya que ciertas anomalías pueden ser detectadas en una etapa temprana. La recopilación de datos es extremadamente importante, ya que proporciona la información que ayuda a comprender las relaciones entre los componentes heterogéneos del sistema.

2. Procesamiento de datos: implica

- Limpieza y análisis de datos,
- Extracción de características,
- Evaluación de características y
- Procesos de selección.

El proceso implica que las series de datos limpias deben someterse a un proceso de extracción de características para seleccionar solo las características importantes y útiles que reflejan el estado de salud del sistema que se está monitoreando. Se debe realizar con modelos de analítica

avanzada predictiva; por ejemplo, para la detección de anomalías se pueden utilizar metodologías SVM (Support vector machines).

3. Análisis Predictivo

El análisis predictivo tiene como objetivo fundamental:

- Conocer y monitorizar el proceso de falla de los equipos;
- Relacionar las fallas y el estado del sistema con la vida útil remanente de los activos industriales eléctricos mediante un indicador HI de la salud de los equipos.

Detección: es el proceso de identificar que un componente se está degradando o que está destinado a fallar a partir de detectar y de reconocer fallos incipientes y/o anomalías en los datos. La detección de fallas se basa típicamente en la cuantificación de las inconsistencias entre el comportamiento real y el esperado en condiciones nominales.

Diagnóstico: es un proceso de detección de fallas que implica:

- Aislamiento (qué componente falla),
- Identificación del modo de falla (cuál es la causa de la falla) y
- Evaluación del nivel de degradación (cuantificación de la gravedad de la falla).

Los diagnósticos se pueden realizar cuando una máquina está en estado de falla completa o en estado defectuoso, se puede analizar junto con sus interacciones para ayudar a diagnosticar las causas. Dependiendo del sistema, este proceso puede ser totalmente automático o requerir de la participación activa del operador, en el último caso, se debe prever la vinculación de la GUI con las bases de datos históricas que se utilizarán para los estudios de analítica predictiva.

Pronóstico: se define como el proceso de predicción del tiempo en el que un componente ya no realizará una función en particular (RUL). Los resultados del pronóstico se utilizan para apoyar la toma de decisiones proactiva. Se debe realizar con modelos de analítica avanzada predictiva basados en i) modelos físicos, ii) modelos basados en datos y/o iii) modelos híbridos.

Dependiendo del caso, cualquiera de los modelos puede hacer predicciones altamente precisas sobre los sistemas industriales eléctricos, pero es necesario estudiar las metodologías disponibles para seleccionar aquella que más se acomode al caso específico.

4. Análisis Prescriptivo (Optimización):

Sobre la base de los resultados de los métodos predictivos desarrollados, las empresas de fabricación pueden determinar las políticas a seguir para la planificación del mantenimiento que ayudarán con menos tiempo de inactividad, mayor rendimiento y una reducción de las pérdidas. Como complemento, los expertos en optimización pueden diseñar modelos/algoritmos que proporcionen las mejores decisiones posibles, que es la práctica moderna.

B.2. Selección del Enfoque Analítico

PHM corresponde a una plataforma informática de analítica predictiva avanzada que permite proyectar previamente los resultados de un proceso a partir de variables de entrada (mediciones) en tiempo real y que puede basarse en la combinación de los principios metodológicos de Inteligencia Artificial (IA), el Aprendizaje Automático (Machine Learning, ML) y la Estimación de Estado (State Estimation, SE).

Las técnicas de pronóstico generalmente se clasifican como basadas en modelos físicos de las componentes (normalmente descrito con base en ecuaciones diferenciales parciales) o basadas en datos. Los métodos basados en modelos utilizan el conocimiento sobre el sistema y los modelos de falla para proporcionar una estimación de RUL. Pueden utilizar el modelo físico del proceso o algunos métodos de estimación estadística basados en estimadores de estado, como el Filtro de Kalman (KF) y/o el filtro de partículas, etc. Sin embargo, el modelo físico de los componentes no siempre es fácil de obtener. Por otro lado, los métodos basados en datos utilizan solo los datos disponibles que se utilizan para entrenar los algoritmos de aprendizaje automático.

B.3. Implementación Computacional

La implementación de modelos de analítica predictiva puede realizarse a partir de librerías preestablecidas en lenguajes como Python o pueden implementarse directamente a los problemas a partir de su formulación algebraica como modelos de optimización. El profesional apropiado para este tipo de modelos es el “científico de datos”.

Zeki et al. (2020) presentan una tabla con los principales proveedores de librerías/plataformas para IA (Inteligencia Artificial) y ML (Machine Learning)

B.3.1. Implementación Analítica Prescriptiva – Optimización de Redes de Activos Industriales Eléctricos

La potencia de los modelos de optimización modernos garantiza la correcta descripción de los sistemas industriales eléctricos actuales, con un grado de detalle antes no imaginado. Adicionalmente, cuando su implementación es completa, captura las ganancias que genera la analítica prescriptiva.

Todos los modelos son de base física, ya que las soluciones óptimas son el resultado de simular de la manera más detallada posible el sistema industrial eléctrico (total o parcialmente), dejando que el algoritmo de optimización seleccione la mejor solución que pueda obtener. Para cada problema de optimización, puede decirse que se requiere un algoritmo que represente el caso específico.

Existen dos tipos de enfoques para enfrentar el problema: i) las metaheurísticas y ii) la programación matemática (también llamados métodos exactos). En este documento se deja de lado la implementación de metaheurísticas porque se considera más apropiado utilizar programación matemática.

B.3.2. Implementación Computacional

La implementación de modelos matemáticos de optimización involucra tecnologías, libres y comerciales, que no siempre son conocidas por los científicos de datos. Por lo tanto, si una empresa desea

La implementación de modelos de analítica prescriptiva requiere del conocimiento apropiado de las diferentes tecnologías que participan en el proceso.

El profesional apropiado para este tipo de modelos es el “modelador matemático” (ingeniero, físico, matemático, científico de datos, economista) como parte de un equipo multidisciplinario que conozca con propiedad el proceso industrial eléctrico. Desafortunadamente no es común encontrar científicos de datos que conozcan con propiedad la programación matemática.

B.3.3. Tecnologías de Optimización

Tal y como se comentó en el Anexo A, de acuerdo con las tecnologías informáticas actuales, al menos cuatro tecnologías de optimización están involucradas en el proceso de desarrollo de un modelo de optimización complejo, se describen a continuación y en la figura:

- Optimización con Solvers
- Lenguajes de Programación
- Plataformas Informáticas de Optimización
- Sistemas Expertos de Optimización

Figura 18: Tecnologías de Optimización



Fuente: Elaboración de los autores

1. Optimización con Solvers

Son productos altamente especializados basados en las leyes matemáticas de la optimización. Son la base de toda optimización matemática de alta complejidad. Para acelerar su rendimiento (tiempo para resolver problemas matemáticos), se implementan metodologías de optimización a gran escala. Se consiguen librerías de solver libres y comerciales, desafortunadamente el rendimiento de la librería GNU es muy inferior al de las comerciales; por lo tanto, en aplicaciones complejas, en la práctica solo son útiles las comerciales. Los tres solvers más “famosos” son: IBM CPLEX, GUROBI y XPRESS. Determinan el costo variable del uso del modelo matemático que se puede asociar al tiempo de solución de los problemas, a menor tiempo, menos costo.

2. Lenguajes de Programación

Productos orientados al desarrollo de modelos de optimización, enfocados a proporcionar al modelador matemático un medio para implementar algoritmos especializados en ciertos formatos

de problemas matemáticos (lineales, no lineales, cuadráticos). Los lenguajes computacionales se comunican con los “solvers” para resolver problemas, las metodologías a gran escala se implementan en este nivel.

Se pueden considerar dos tipos de lenguajes:

- Bajo nivel: Lenguajes de computación de propósito general como C, PYTHON, ...
- Alto nivel: Lenguajes de computación algebraicos (como GAMS, AMPL, MOSEL, GLPK, IBM OPL, AIMMS, LINGO, SAS Optimization, y OPTEX) especialmente orientados a modelos formulados algebraicamente.

Para los lenguajes de propósito general existen librerías de objetos especializados en programación matemática para facilitar la codificación de los modelos y hacerlos más competitivos con los lenguajes de alto nivel. Los lenguajes algebraicos apropiados para formular modelos complejos son de tipo comercial, es decir requieren de licencia para su uso. Los lenguajes de computación determinan el costo de desarrollo del modelo matemático, se espera que los de alto nivel requieran menos tiempo de desarrollo.

3. Plataformas Informáticas de Optimización

Plataformas informáticas que integran todos los aspectos informáticos necesarios para la implantación de los Sistemas de Apoyo a la Decisión (DSS). Facilitan la puesta en marcha (despliegue) y el mantenimiento de los DSS para una organización, integrando múltiples modelos matemáticos, bases de datos e interfaces de visualización. Determinan el costo de mantenimiento y administración del sistema de modelos.

4. Sistemas Expertos de Optimización

Sistemas expertos y robots cognitivos que generan algoritmos en múltiples tecnologías de optimización para múltiples modelos matemáticos, simplificando el proceso de implementación de soluciones complejas e integradas. Los sistemas expertos almacenan información sobre los modelos desarrollados y las corridas realizadas con estos modelos y mejoran el conocimiento del modelador matemático, ya que asume la responsabilidad de todas las tareas sistemáticas y repetitivas, lo que implica la implementación de múltiples modelos matemáticos que deben coordinarse entre sí. Este es el futuro de la programación matemática, su uso no está muy difundido, pero ya existen productos en el mercado como OPTEX Optimization Expert System. Disminuyen sensiblemente todos los costos relacionados en el diseño, implementación, uso y mantenimiento de sistema de modelos de analítica avanzada.

B.3.4. Arquitectura Cliente – Servidor

La tendencia moderna de distribuir las aplicaciones en múltiples computadores especializados en los que los servicios que prestan también incluyen los sistemas de soporte de decisiones. El diagrama presenta la conectividad de un SSD moderno:



Optimización Server: computador de alto rendimiento especializado en resolver los problemas de optimización. Allí residen las licencias de uso de los solvers.



Data Server: computador especializado en mantener las bases de datos, normalmente tipo SQL, donde residen los datos entrada-salida de los modelos matemáticos.



Cliente: computadores personales o estaciones de trabajo desde donde se accede a los servicios del SSD.

Adicional a la red fundamental, existirán conexiones con otras aplicaciones y bases de datos de uso “corriente” en la organización usuaria.

C. Referencias bibliográficas

Este estudio ha sido escrito con información proveniente principalmente de los siguientes artículos, los cuales han sido editados por los autores quienes asumen la responsabilidad de la veracidad del texto editado:

- Aerialtronics. Drones para la inspección de líneas eléctricas.
<https://www.aerialtronics.com/es/aplicaciones/drones-para-la-inspeccion-de-lineas-electricas>
- Ahmad W, Khan S-A, Kim J-M. A Hybrid Prognostics Technique for Rolling Element Bearings using Adaptive Predictive Models. IEEE Trans Ind Electron 2017.
- Al-Ahmar, E.; Benbouzid, M. E. H.; Amirat, Y.; Elghali, S. E. B., DFIG-based wind turbine fault diagnosis using a specific discrete wavelet transform, 2008 18th International Conference on Electrical Machines, Vilamoura, Portugal, 2008
- An, D.; Kim, N.H.; Choi, J.H.. Practical Options for Selecting Data-Driven or Physics-Based Prognostics Algorithms with Reviews. Reliab Eng Syst Saf 2015;133:223–36.
- Atamuradov, V.; Medjaher, K.; Dersin, P.; Lamoureux, B.; Zerhouni, N.. "Prognostics and Health Management for Maintenance Practitioners - Review, Implementation and Tools Evaluation". International Journal of Prognostics and Health Management.
- Ball, J.E., Anderson, D.T., Chan, C.S., 2017. A Comprehensive Survey of Deep Learning in Remote Sensing: Theories, Tools and Challenges for The Community. arXiv 11. doi: 10.1117/1.jrs.11.042609, arXiv:1709.00308
- Banco Interamericano de Desarrollo (BID). La ruta energética de América Latina y el Caribe. 2022
- Barbosa, J.P.. Deep Learning Approach for UAV Visual Electrical Assets Inspection. Mestrado em Engenharia Eletrotécnica e de Computadores. Novembro de 2020. Instituto Politécnico do Porto
- Ben Ali J, Fnaiech N, Saidi L, Chebel-Morello B, Fnaiech F. Application of Empirical Mode Decomposition and Artificial Neural Network for Automatic Bearing Fault Diagnosis Based on Vibration Signals. Appl Acoust 2015;89:16–27.
- Ben Ali, J.; Fnaiech, N.; Saidi, L.; Chebel-Morello, B.; Fnaiech, F.. Application of Empirical Mode Decomposition and Artificial Neural Network for Automatic Bearing Fault Diagnosis Based on Vibration Signals. Appl Acoust 2015;89:16–27.
- Benbouzid, M.; Berghout, T.; Sarma, N.; Djurović, S.; Wu, Y.; Ma, X. Intelligent Condition Monitoring of Wind Power Systems: State of the Art Review. Energies 2021, 14, 5967
- Brandão, M. B.. Optimizing the Assets Replacements Investments on the Power Transmission Grid.
- Bretscher O. Linear Algebra with Applications. New Jersey: Prentice Hall; 1995.
- Cataño, J. A. A.. Estudio del comportamiento real de la fase iii de la curva de la bañera a través de la aproximación de una distribución a la vida útil de bombillos de frenado automotriz. Universidad EAFIT, Escuela de Ingeniería, Departamento de Ingeniería Mecánica, Medellín, 2014
- Kulkarni, C. S.. Systems Health Monitoring and Prognostics using Model Based Approach. 2018
- Chmura, L.A.. Life-Cycle Assessment of High-Voltage Assets Using Statistical Tools. 2016
- Chou, J-S.; Chiu, C-K.; Huang, I-K.; Chi, K-N.. Failure Analysis of Wind Turbine Blade under Critical Wind Loads. Eng Fail Anal 2013;27:99–118.
- Deng, C.; Shengwei Wang, S.; Zhi Huang, Z.; Zhongfu Tan, Z.; and Ji Liu, J.. Unmanned Aerial Vehicles for Power Line Inspection: A Cooperative Way in Platforms and Communications. Journal of Communications, vol. 9, no. 9, pp. 687-692, 2014.
- CIGRÉ, "422 - Transmission Asset Risk Management," 2010.
- Çınar, Z.M.; Abdussalam Nuhu, A.; Zeeshan, Q.; Korhan, O.; Asmael, M.; Safaei, B. Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0. Sustainability 2020
- Edward F. Hogge et al. Verification of a Remaining Flying Time Prediction System for Small Electric Aircraft
- Ekwaro-Osire, S.; Gonçalves, A. C.; Alemayehu, F. M.. "Probabilistic Prognostics and Health Management of Energy Systems," Probabilistic Progn. Heal. Manag. Energy Syst., no. February 2018, pp. 1–277, 2017
- Enterprise. Power Grid Management
<https://enterprise.dji.com/electricity/power-grid-management>
- EPRI, "Power Delivery Asset Management Decision Making Process," December 2008.
- European Union - Sustainable Energy Handbook, February 2016. Module 6.1. Simplified Financial Models.
- Fan, X.; Liu, B.; Liu, J.; Ding, J.; Han X.J.; Deng Lv, X.; Xie, Y.; Chen, B.; Hu, W.; Zhong, C.. Battery Technologies for Grid-Level Large-Scale Electrical Energy Storage. Transactions of Tianjin University (2020) 26:92–103.

- Gelernter, D.. Mirror worlds or the day software puts the universe in a shoebox: how will it happen and what it will mean. 1991
- Goebel, K. ,; Abhinav Saxena,A.; Matt Daigle, M.; Jose Celaya, J.; Indranil Roychoudhury, I.. "Introduction to Prognostics". NASA Ames Research Center, Prognostics Center of Excellence. (2012)
- Goebel, K.;, Abhinav Saxena, A. ,; Matt Daigle, M. ,; Jose Celaya, J. ,; Indranil Roychoudhury, I.. Introduction to Prognostics. 2018.
- Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S.,Courville, A., Bengio, Y., 2014. Generative adversarial networks Advances in Neural Information Processing Systems. arXiv:1406.2661. 2014
- Grieves, M.. Origins of the Digital Twin Concept. 2016
- Gulati, A.; and J. Ghorai, J.. Prognostic Health Management for Turbofan Engines. CS230: Deep Learning, Winter 2018, Stanford University, CA
- Hogge, E. F., Bole, B. M.; Vazquez, S. L.; Celaya, J. R.; Strom, T. H.; Hill, B. L.; Smalling, K. M.; Quach, C. C.. Verification of a Remaining Flying Time Prediction System for Small Electric Aircraft. Annual Conference of the Prognostics and Health Management Society, 2015.
- Informed Infrastructure. FAA Approves Limited Use Of Drones for San Diegeo Gas & Electric. 2014 <https://informedinfrastructure.com/9668/faa-approves-limited-use-of-drones-for-san-diegeo-gas-electric/>
- International Energy Agency (IEA). Renewable Energy Technologies: Solar Energy Perspectives. 2011
- International Energy Agency (IEA), Smart Grids, 2022, Paris <https://www.iea.org/reports/smart-grids>
- Jones, D.. Global Electricity Review 2022. 2022
- Jongen, R. A., .. Statistical Lifetime Management for Energy Network Components, Delft, 2012.
- Julier, S. J.; Uhlmann, J. K.. A New Extension of the Kalman Filter to Nonlinear Systems. In Proc. of AeroSense: The 11th Int. Symp. On Aerospace/Defence Sensing, Simulation and Controls., 1997.
- Kadim, E.J.; Azis, N.; Jasni, J.; Ahmad, S.A.; Talib, M.A. Transformers Health Index Assessment Based on Neural-Fuzzy Network. Energies 2018, 11, 710.
- Kalman, R. E.. A New Approach to Linear Filtering and Prediction Problems, Transactions of the ASME - Journal of Basic Engineering Vol. 82: pag. 35-45. 1960.
- Kongphet, V.; Migan-Dubois, A.; Delpha, C.; Diallo, D.; Lechenadec, J. -Y.. Photovoltaic Fault Detection and Diagnosis: Which Level of Granularity for PV Modeling?. 2020 Prognostics and Health Management Conference (PHM-Besançon), Besancon, France, 2020, pp. 180-186.
- Kongphet, V.; Migan-Dubois, A.; Delpha, C.; Diallo, D.; Lechenadec, J. -Y... Photovoltaic Fault Detection and Diagnosis: Which Level of Granularity for PV Modeling?. 2020 Prognostics and Health Management Conference (PHM-Besançon), Besancon, France, 2020, pp. 180-186.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. Imagenet Classification with Deep Convolutional Neural Networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1. Curran Associates Inc., Red Hook, NY, USA, pp. 1097–1105
- Langåker, H-A; Kjerkreit, H; Syversen, CL; et al..Helge-André Langa"ker et al. An autonomous drone-based system for inspection of electrical substations. International Journal of Advanced Robotic Systems. March-April 2021: 1–15
- Lee, J.; F. Wu, F.; W. Zhao, W.; M. Ghaffari, M.; L. Liao, L.; and D. Siegel, D.. "Prognostics and Health Management Design for Rotary Machinery Systems - Reviews, Methodology and Applications," Mech. Syst. Signal Process., vol. 42, no. 1–2, pp. 314–334, 2014.
- Lewis, F.L.. IEEE. Intelligent Fault Diagnosis & Prognosis. Automation & Robotics Research Institute (ARRI), The University of Texas at Arlington
- Li, X.; Duan, F.; Mba, D.; Bennett, I. et al.. Rotating Machine Prognostics Using System-Level Models. 2018.
- Ma, J., Jiang, X., Fan, A., Jiang, J., Yan, J., 2021. Image Matching from Handcrafted to Deep Features: A survey. International Journal of Computer Vision. Advance online publication
- Ma, Z.; Zhou, L.; Sheng, W.. "Analysis of the new asset management standard ISO 55000 and PAS 55," 2014 China International Conference on Electricity Distribution (CICED), Shenzhen, China, 2014, pp. 1668-1674.
- Malveiro, M.; R. Martins, R.; and R. Carvalho, R.. Inspection of High Voltage Overhead Power Lines with UAVs. 23rd International Conference on Electricity Distribution Lyon, 15-18 June 2015.
- Mancuso, A.; Compare, M.; Salo, A.; Zio, E. "Optimal Prognostics and Health Management-Driven Inspection and Maintenance Strategies for Industrial Systems. Reliability Engineering and System Safety.
- Mártil, I.. Funcionamiento de una batería de ion-litio. Material Eléctrico. 2019
- Martín, M. J.; Violeta, B.; Clavero Sousa, H.; Garrido López, J. R.. Les oiseaux et les réseaux électriques en Afrique du Nord. IUCN Centre for Mediterranean Cooperation. 2019
- McKinsey & Company. Digitally enabled reliability: Beyond predictive maintenance. 2018.

- MehdipourPicha, H.; Bo, R.; Chen, H.; Rana, M. M.; Huang, J.; Hu, F.. Transformer Fault Diagnosis Using Deep Neural Network. 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), Chengdu, China, 2019, pp. 4241-4245.
- Metaxiotis, K.; Kagiannas, A.; Askounis, D.; Psarras, J.. Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher, Energy Conversion and Management, Volume 44, Issue 9, 2003, Pages 1525-1534.
- Mirjalili, S.; Seyedali, and Andrew Lewis, A... The Whale Optimization Algorithm, Advances in Engineering Software, Volume 95, 2016, Pages 51-67.
- Mohebbi, B.; Tahmassebi, A.; Meyer-Baese, A.; Gandomi, A.H... (2020). Probabilistic Neural Networks: a Brief Overview of Theory, Implementation, and Application. Elsevier. Pp. 347–367.
- Mundo Eléctrico. Sistemas solares fotovoltaicos híbridos. 2018
- National Grid, "Electricity Transmission Annual Summary 2014/15 - Network Innovation Allowance," 2015.
- Natti, S.; Kezunovic, M.. "A Risk-Based Decision Approach for Maintenance Scheduling Strategies for Transmission System Equipment," Proceedings of the 10th International Conference on Probabilistic Methods Applied to Power Systems, Rincon, PR, USA, 2008, pp. 1-6..
- Nordgard, D. E.; Sand, K.; Gjerde, O.; Catrinu, M. D.; Lassila, J.; Partanen, J.; Bonnoit, S.; Aupied, J.. "A Risk Based Approach to Distribution System Asset Management and A Survey Of A Perceived Risk Exposure Among Distribution Companies," in 19th International Conference on Electricity Distribution, Vienna, 2007.
- OFGEM, "RIIO Electricity Transmission Annual Report 2014-15," 10 Dezembro 2015.
- Osco, L.P.; Marcato Junior, J.; Ramos, A.P.M.; Jorge, L.; Fatholahi, S.N.; Silva, J.A.; Matsubara, E.T.; Pistori, H.; Gonçalves, W.N.; Li, J.. A Review on Deep Learning in UAV Remote Sensing. International Journal of Applied Earth Observations and Geoinformation (2021).
- Pandey, P.; Patel, V.; George, N.V.; Mallajosyula, S.S. KELM-CPPpred: Kernel Extreme Learning Machine Based Prediction Model for Cell-Penetrating Peptides. J. Proteome Res. 2018, 17, 3214–3222.
- Paris, P. C.; Erdogan, F.. A Critical Analysis of Crack Propagation Laws. ASME J Basic Eng. 1963;85:528–34.
- Phuyal, S.; Diwakar Bista, D.; and Rabindra Bista, R.. Challenges, Opportunities and Future Directions of Smart Manufacturing: A State of Art Review. Sustainable Futures 2 (2020)
- Pineda, I.; Azau, S.; Moccia, J.; Wilkes, J.. Wind in Power: 2013 European Statistics. Tech. Rep., no. February, pp. 1–12, 2014.
- PricewaterhouseCoopers, "Asset Management: Powering Your Journey to Success," PwC Power and Utilities Discussion Paper, 2014.
- Quaternium. Take Your Time For Accurate Inspection.
<https://www.quaternium.com/uas/inspection/>
- Rabbani, M.; Panahi, H. An Efficient Hybrid Artificial Immune Algorithm for Clustering. In Proceedings of the 2008 Eighth International Conference on Hybrid Intelligent Systems, Barcelona, Spain, 10–12 September 2008; pp. 374–379.
- Ramachandran, B.; Srivastava, S.K.; Edrington, C.S.; Cartes, D.A. An Intelligent Auction Scheme for Smart Grid Market Using a Hybrid Immune Algorithm. IEEE Trans. Ind. Electron. 2011, 58, 4603–4612.
- Ramezani, S.; Moini, A.; Riahi, M.Saeed Ramezani et al. Prognostics and Health Management in Machinery: A Review of Methodologies for RUL prediction and Roadmap. International Journal of Industrial Engineering & Supply Chain Management, Vol. 6, Issue 1, (2019) 38-61
- Riley, D.; Jay Johnson, J.. Photovoltaic Prognostics and Health Management using Learning Algorithms. Sandia National Laboratories, Albuquerque, NM, USA, 978-1-4673-0066-7/12 ©2011 IEEE
- Saidi, L. and Benbouzid, M. Prognostics and Health Management of Renewable Energy Systems: State of the Art Review, Challenges, and Trends. Electronics 2021, 10, 2732. <https://doi.org/10.3390/electronics10222732>
- Saidi, L.; Ben Ali, J.; Benbouzid, M.; Bechhofer, E. An Integrated Wind Turbine Failures Prognostic Approach Implementing Kalman Smoother with Confidence Bounds. Appl. Acoust. 2018, 138, 199–208.
- Saidi, L.; Benbouzid, M. Prognostics and Health Management of Renewable Energy Systems: State of the Art Review, Challenges, and Trends. Electronics 2021, 10, 2732
- Saxena, A. ; Celaya, J. ; Saha, B.. On Applying the Prognostic Performance Metrics. In: Paper presented at the Annual Conference of the Prognostics and Health Management Society, San Diego, California, USA, 27 September–1 October 2009.
- Shafto, M.; Conroy, M.; Doyle, R.; Glaessgen E., Kemp, C.; Le Moigne, J.; Wang, L.. DRAFT Modeling, Simulation, Information Technology & Processing Roadmap. Technology Area 11, 2010.

- Shang, H.; Xu, J.; Zheng, Z.; Qi, B.; Zhang, L..Haikun Shang et al. A Novel Fault Diagnosis Method for Power Transformer Based on Dissolved Gas Analysis Using Hypersphere Multiclass Support Vector Machine and Improved D–S Evidence Theory. *Energies* 2019, 12, 4017.
- Smit J.J., Quak B., Galski E. Integral Decision Support for Asset Management of Electrical Infrastructures. Presented at the IEEE Systems, Man and Cybernetics Conference, 2006.
- Specht, D. F. (1990). "Probabilistic neural networks". *Neural Networks*. 3: 109–118.
- Sundaram, S.; Zeid, A. Smart Prognostics and Health Management (SPHM) in Smart Manufacturing: An Interoperable Framework. *Sensors* 2021.
- Taheri, E.; Kolmanovsky, I., Gusikhin, O.. Survey of prognostics methods for condition-based maintenance in engineering systems. 2019
- The Institute of Asset Management, "Asset Management - An Anatomy," 2015
- United Kingdom Parliament. Energy network costs: transparent and fair?.
http://www.publications.parliament.uk/pa/cm201415/cmselect/cmenergy/386/38604.html#_idTOCAAnchor-16
- Venayagamoorthy, G. K., Dynamic, Stochastic, computational & Scalable Technologies for Smart Grids, *IEEE Computational Intelligence Magazine* 6 (3) (August 2011) 22–35.
- Whittingham, M. S..The Origins of the Lithium Battery. Nobel Lecture. 2019
- Wijnia, Y.C.. Processing Risk in Asset Management - Exploring the Boundaries of Risk Based Optimization Under Uncertainty for an Energy Infrastructure Asset Manager, Delft, 2016.
- Xiao, L.Y.; Shao, W.; Ding, X.; Wang, B.Z. Dynamic Adjustment Kernel Extreme Learning Machine for Microwave Component Design. *IEEE Trans. Microw. Theory Tech.* 2018, 66, 4452–4461.
- Zhang, W.; Yang, X.; Deng, Y.; Li, A. An Inspired Machine-Learning Algorithm with a Hybrid Whale Optimization for Power Transformer PHM. *Energies* 2020, 13, 3143.
- Zio, E.. Prognostics and Health Management (PHM): Where are we and where do we (need to) go in theory and practice. *Reliability Engineering and System Safety* 218 (2022) 108119.

