

MÉTODOS DE APRENDIZAJE AUTOMÁTICO EN LA GESTIÓN DE VIDA DE EQUIPOS

ENRIQUE NAVARRO

Dpto. de Ingeniería Química y Nuclear (MEDASEGI)
Técnico de investigación
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

ISABEL MARTÓN

Profesora Titular
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

ANA ISABEL SÁNCHEZ

Catedrática
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

SEBASTIÁN MARTORELL

Catedrático
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

INTRODUCCIÓN

El Plan Nacional Integrado de Energía y Clima contempla la operación de las centrales nucleares (CCNN) hasta un posible cierre escalonado durante el período comprendido entre 2025 y 2035. De este modo, las centrales nucleares españolas habrán acumulado una larga experiencia que ronda los 40 años de operación, debiendo mantener en todo momento los más altos estándares de seguridad y fiabilidad en sus sistemas. Ante este escenario de operación de las centrales cerca de su vida de diseño, e incluso superándola en algunos casos, resulta aún más importante incrementar el esfuerzo en investigación y desarrollo para mantener los citados estándares de fiabilidad y seguridad de funcionamiento.

Desde algunos organismos reguladores, como la Comisión Reguladora Nuclear (NRC) en Estados Unidos, se promueve la incorporación de técnicas de inteligencia artificial (IA) dentro de su Plan Estratégico para 2023-2027 [1]. Según la NRC, la implementación de la IA en el sector tendría una importancia clave para mejorar las aplicaciones informadas en el riesgo.

Para los equipos cuyo mantenimiento está basado en la condición, el uso de métodos de IA podrá mejorar el reconocimiento de patrones de degradación y envejecimiento, permitiendo obtener una mejor diagnosis y pronóstico del

estado de salud y unas proyecciones de la tasa de fallo más realistas. Además, para dichos equipos y también aquellos en los que el mantenimiento programado se realice por tiempo en lugar de por condición, se podrán desarrollar modelos RAM (fiabilidad, disponibilidad y mantenibilidad) a través de datos del histórico de mantenimiento que permitirán estimar de manera más precisa la eficacia del programa de gestión de vida y mantenimiento.

Por otro lado, el uso de métodos de optimización heurística, como los algoritmos genéticos, junto con la flexibilidad que aportan los modelos de salud basados en la condición y los modelos RAM, que integran de forma explícita el estado de degradación, la fiabilidad y el mantenimiento de los equipos, permitirá, por primera vez, optimizar de manera conjunta la vigilancia y el mantenimiento. Esto hará posible aplicar la optimización a una gran variedad de equipos pertenecientes a distintos sistemas, cada uno con sus propias características, especificaciones y necesidades de vigilancia y mantenimiento.

En este contexto, el grupo Medioambiente y Seguridad Industrial (MEDASEGI) de la Universitat Politècnica de València está trabajando en un proyecto de investigación subvencionado por el Consejo de Seguridad Nuclear (CSN), con el objetivo de mejorar la gestión de vida y mantenimiento de las CCNN en la Operación a Largo Plazo (OLP). Este proyecto se enmarca

en una de las líneas propuestas por el CSN, concretamente la línea: *Desarrollo y aplicación de técnicas de inteligencia artificial para la mejora de la gestión de vida y el mantenimiento de centrales nucleares*.

El proyecto propuesto por MEDASEGI pretende generar herramientas basados en métodos de aprendizaje automático para que sirvan de apoyo en el proceso de toma de decisiones de las centrales en la OLP. En este artículo se muestra una breve descripción del marco metodológico propuesto en el proyecto anteriormente mencionado y un caso de aplicación, centrado en una de las tareas del proyecto, en el que se muestran los resultados obtenidos en el modelado de la fiabilidad a través del estado de salud de equipos utilizando modelos de aprendizaje automático.

METODOLOGÍA

El objetivo del proyecto de investigación se centra en el desarrollo de aplicaciones y técnicas de inteligencia artificial para la mejora de la gestión de vida y mantenimiento de centrales nucleares en la OLP. Para alcanzar este objetivo en el proyecto se propone una metodología cuyas tareas principales se presentan a continuación:

- Tarea 1: Identificar los equipos de seguridad críticos y sus modos de fallo dominantes en alcance.
- Tarea 2: Desarrollar modelos RAM avanzados del comportamiento de los equipos críticos de seguridad sometidos tanto a mantenimiento preventivo por tiempo como por condición. Los modelos basados en mantenimiento por condición permitirán diagnosticar el

estado de salud del equipo y pronosticar la evolución de su fiabilidad y degradación.

- Tarea 3: Aplicar métodos heurísticos para la planificación del mantenimiento y renovación de equipos utilizando los modelos RAM anteriores. Estos métodos podrán utilizarse para optimizar el programa de fiabilidad y la gestión de vida de los equipos de planta permitiendo una toma de decisiones más realista.

En las siguientes secciones se detallan las tareas y los avances conseguidos en cada una de ellas.

Tarea 1: Identificación de equipos críticos y mecanismos de degradación

Para adquirir una visión general del problema tratado, en primer lugar se realizó una revisión bibliográfica enfocada en la identificación de los equipos con un mayor impacto en la seguridad de planta, los efectos del envejecimiento más comunes en cada uno de ellos y los mecanismos de degradación que los propiciaban. Entre la información consultada se encuentran documentos como el Plan de Gestión de la Vida Útil de una CN con la que el grupo trabajó anteriormente, la base de datos de IGALL [2] o las “EPRI Continuous On-Line Monitoring (COLM) Quickguides” [3].

Como resultado de la revisión bibliográfica se identificaron cuatro grupos principales de equipos críticos y se cuantificaron sus mecanismos de degradación más frecuentes, tal y como se muestra en la **Figura 1**. Además, el estudio también permitió conocer y registrar las mejores técnicas y herramientas para monitorizar la condición de los equipos en alcance de las CCNN.




Figura 1. Equipos críticos identificados y sus principales mecanismos de degradación.




Figura 2. Perfil de riesgo para una combinación fija de TIs y diagrama de dispersión para todas las combinaciones.

Tarea 2: Desarrollo de modelos de mantenimiento

La segunda tarea del proyecto se centra en el desarrollo de modelos RAM que incorporen el efecto del mantenimiento, ya sea por tiempo o por condición.

En el caso del mantenimiento por tiempo, las intervenciones se organizan de forma periódica, en intervalos de tiempo establecidos. Generalmente, las frecuencias entre intervenciones de mantenimiento son más cortas cuanto más importante es el equipo para preservar la seguridad de la planta, lo que da lugar a diferentes grupos de “intervalos de mantenimiento” (ej: semanal, mensual, trimestral, etc).

Por otro lado, el mantenimiento basado en la condición estima el estado de salud del equipo a partir de indicadores de degradación, que pueden ir desde inspecciones visuales hasta señales monitorizadas en continuo, y, en función de la desviación respecto de las condiciones normales de operación, se decide si llevar a cabo el mantenimiento o no.

Debido a la diferencia de filosofía entre ambos enfoques, la metodología empleada para desarrollar los modelos debe adecuarse para cada caso.

- Mantenimiento programado por tiempo

Esta tarea se encuentra avanzada y ya se ha presentado un modelo, basado en técnicas de aprendizaje automático (XGBoost), capaz de estimar el nivel de riesgo de una instalación y el impacto de las políticas de vigilancia. El modelo en cuestión predice de forma satisfactoria el valor de la Frecuencia de Daño al Núcleo (FDN, en inglés CDF) a partir de los parámetros de fiabilidad que gobiernan los modos de fallo de los equipos y una serie de intervalos de prueba (TIs) a equipos en espera, permitiendo cuantificar el impacto de variar la frecuencia de los mencionados TIs. Los resultados obtenidos se encuentran publicados en [4]. En la **Figura 2**, se muestra el perfil de riesgo generado por el modelo para una combinación dada de TIs (izda.) y un diagrama de dispersión comparando el ajuste del perfil de riesgo generado por el modelo respecto al software comercial (*Code-based*) para 27 combinaciones de TIs diferentes (dcha.).

- Mantenimiento por condición

En el caso de los modelos basados en la condición, el objetivo es aprovechar las señales de los equipos monitorizados para construir indicadores de salud que permitan decidir

cuándo llevar a cabo las tareas de mantenimiento. Para ello, primero se relaciona el valor de la señal con la fiabilidad y, seguidamente, se ajusta un modelo de regresión para pronosticar su evolución, permitiendo anticiparse a los fallos antes de que se produzcan.

Esta es la tarea más reciente y en la que más tiempo ha invertido el grupo de investigación últimamente, por lo que el Caso de Aplicación profundiza en la metodología seguida para desarrollar estos modelos, que consta de las siguientes etapas:

1. Preprocesado y selección de la señal.
2. Ajuste del modelo de fiabilidad.
3. Inclusión del efecto del mantenimiento.
4. Desarrollo del modelo de regresión.

Tarea 3: Heurísticas de optimización

Esta tarea está dedicada a desarrollar y aplicar métodos heurísticos de optimización, como pueden ser los algoritmos evolutivos, a los modelos de la Tarea 2.

Dado que estos modelos incluyen una gran cantidad de parámetros, como los criterios de actuación en el preventivo, la frecuencia de los mantenimientos por tiempo o los TIs a equipos en espera, la optimización persigue obtener una combinación de parámetros que garantice una solución cercana a la óptima.

Esta solución debe ser compatible con los requisitos legales y la realidad operativa de la planta, por lo que hay que considerar restricciones como la normativa vigente y la capacidad de recursos en la modelización del problema de optimización. Uno de los trabajos realizados por el grupo en el contexto de esta tarea se puede consultar en [5]. En esta publicación, se utiliza el modelo desarrollado en la Tarea 2.2.1 para encontrar una combinación de TIs que reduzcan el valor de la FDN media, demostrando la viabilidad de la metodología propuesta para generar herramientas que den soporte a la toma de decisiones informada en el riesgo.

CASO DE APLICACIÓN: MANTENIMIENTO POR CONDICIÓN

El presente caso de aplicación muestra los avances en la Tarea 2.2.2 del proyecto. Ante la falta de datos de operación

reales, se ha empleado la base de datos (BBDD) C-MAPSS (*Commercial Modular AeroPropulsion System Simulation*), que simula la evolución de la condición de turbinas de avión hasta el fallo. Estos datos han sido generados por la NASA y se encuentran disponibles en [6]. La BBDD se compone de cuatro subsets que combinan diferentes tipologías de fallo y condiciones de operación. Sin embargo, el Caso de Aplicación se centra en el caso más sencillo, subset FD001, donde sólo se considera un tipo de fallo y condiciones de operación constantes.

Preprocesado y selección de la señal

Dado que el fenómeno que se pretende modelizar es la degradación, las señales más interesantes para relacionarlas con este proceso serán aquellas que presenten un comportamiento mayormente monotónico (crecientes o decrecientes), ya que, sin el efecto del mantenimiento, la degradación tiende a crecer de forma continua. No obstante, atendiendo al ruido presente en los datos, se considera conveniente realizar un paso previo para suavizar las señales. Para ello, se aplica una media móvil exponencial (EMA) con un $\alpha = 0.05$, que es el parámetro que controla el nivel del suavizado. La **Figura 3** muestra el efecto de aplicar la EMA sobre uno de los sensores.




Figura 3. Evolución del sensor 4 para el motor 8 antes y después del preprocesado.

Una vez que se tienen las señales suavizadas, se descartan las que son constantes y se calcula el coeficiente de correlación de Pearson entre los sensores restantes y el número de ciclos (vuelos) que lleva operando la turbina. Se toma como referencia el número de ciclos porque, por su propia definición, se trata de una variable monótona creciente. A continuación, en la **Tabla 1**, se muestra el valor del coeficiente de correlación de los diferentes sensores.

Atendiendo a la **Tabla 1**, la mayoría de los sensores presentan una correlación fuerte, con cinco de ellos por encima de 0.63. Para el desarrollo del modelo por condición, finalmente se escogió el sensor 4, que se corresponde con la temperatura (°R) a la salida de la turbina de baja presión (más información sobre los sensores se puede encontrar en [7]).

Ajuste del modelo de fiabilidad

Habiendo seleccionado la señal asociada al indicador de salud, el siguiente paso consiste en vincular un modelo de fiabilidad. Para ello, se prueba a ajustar diferentes distribuciones sobre el histograma de valores del sensor 4 en el momento del fallo. La **Tabla 2** recoge las distribuciones probadas y el valor de su verosimilitud.

Dado que la distribución Weibull es la que obtiene una mayor verosimilitud, se utiliza para vincular el valor del sensor con la fiabilidad a través de la siguiente ecuación:

$$R(\text{sensor4}) = \begin{cases} 1, & \text{sensor4} \leq 1413.98 \\ \exp \left[- \left(\frac{\text{sensor4} - 1413.98}{8.98} \right)^{4.73} \right], & \text{sensor4} \geq 1413.98 \end{cases}$$

En la **Figura 4** se muestran, por una parte, el histograma de valores del sensor 4 en el momento del fallo, la distribución Weibull ajustada y la función de fiabilidad definida en la ecuación (1) y, por otra, el resultado de traducir la señal que aparecía en la **Figura 3** a términos de fiabilidad.

Al expresar la fiabilidad en función del sensor se vuelve factible establecer un límite (R_{lim}) a modo de criterio para la intervención de mantenimiento. En este caso, si se decidiese trabajar con un valor límite de fiabilidad de 0.9, el valor correspondiente del sensor 4 sería de 1419.5 (°R).

Sensor	op.set1	op.set2	op.set3	s2	s3	s4	s6	s7	s8
Correlación	-	-	-	0.61	0.65	0.64	0.24	-0.60	0.45
Sensor	s9	s11	s12	s13	s14	s15	s17	s20	s21
Correlación	0.46	0.62	-0.60	0.46	0.37	0.62	0.66	-0.64	-0.64

Tabla 1. Coeficiente de correlación de Pearson entre los sensores y el número de ciclos.

Distribuciones	Exponencial	Normal	Lognormal	Weibull
Verosimilitud	-251.36	-212.43	-212.43	-210.97

Tabla 2. Verosimilitud de las funciones de distribución ajustadas sobre el sensor 4 en el fallo.





Figura 4. Histograma de fallos con el ajuste de fiabilidad (izda.) y evolución para el motor 8 (dcha.).

Inclusión del Efecto del Mantenimiento

Con la relación entre el valor del sensor y la fiabilidad definida, se puede incluir el efecto del mantenimiento en el estado de salud del equipo que se está monitorizando. A continuación, se presentan unos ejemplos sobre cómo se registraría la evolución de la condición de un equipo incluyendo las intervenciones de mantenimiento. En la **Figura 5** y **Figura 6** se puede observar cómo varía el comportamiento, tras cinco mantenimientos, de un equipo monitorizado cuando se modifican parámetros como la efectividad ε (que se estimaría a partir del histórico de planta) y el criterio de actuación (valor límite de fiabilidad,

R_{lim}). Al no disponer de un histórico de intervenciones de mantenimiento, en cada una de las figuras se ha considerado una reducción proporcional constante después de cada intervención, aunque con diferente efectividad.

Las **Figuras 5 y 6** ponen de manifiesto que, para el conjunto de datos utilizado, el impacto de un mantenimiento efectivo es mucho mayor que el límite de fiabilidad establecido, permitiendo operar durante más tiempo con mayor seguridad. Además, disponer de la evolución de la degradación a medio plazo tras las intervenciones de mantenimiento ofrece un valioso punto de vista para evaluar el momento en que conviene más reemplazar un equipo





Figura 5. Evolución de la fiabilidad y del sensor 4 suponiendo $\varepsilon = 0.7$ y $R_{lim} = 0.8$.





Figura 6. Evolución de la fiabilidad y del sensor 4 suponiendo $\varepsilon = 0.9$ y $R_{lim} = 0.9$.

que continuar con su mantenimiento, dando soporte extra a la gestión de activos.

Desarrollo del modelo de regresión

Finalmente, se desarrolla un modelo para la prognosis del comportamiento del sensor a futuro con el objetivo de anticiparse al momento del mantenimiento y poder gestionar con anterioridad los materiales y el personal necesario para llevarlo a cabo. Para ello, se utiliza un modelo mixto cuadrático [8] por su capacidad de captar curvaturas y diferenciar comportamientos entre motores. El modelo utiliza los últimos 40 ciclos disponibles para ajustarse y, a partir de ahí, proyectar la evolución del sensor hasta alcanzar el límite de fiabilidad establecido, obteniéndose un resultado como el que refleja la **Figura 7**.




Figura 7. Ciclo en el que se alcanzará el límite de fiabilidad según el modelo cuadrático mixto (15 y 55 ciclos antes del límite).

El gráfico de la **Figura 7** sugiere que la precisión del modelo aumenta conforme se utilizan ciclos más cercanos al momento de alcanzar el límite. Con motivo de cuantificar la evolución de la precisión, se calcula la raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE) para los últimos 80 ciclos de cada motor. Los resultados obtenidos se muestran en la **Figura 8**.




Figura 8. Evolución del RMSE y del MAE conforme se aproxima el cruce real del límite de fiabilidad.

Tal y como muestra el gráfico, el error de predicción es elevado cuando la estimación se realiza con muchos ciclos de antelación, pero disminuye a medida que se incorporan ciclos más próximos al momento del cruce. A la vista de estos resultados, el modelo no está preparado para dar soporte a la gestión del mantenimiento a lo largo de todo el ciclo de vida del activo, a pesar de mostrar cierta capacidad para anticipar el momento en que debe ejecutarse la intervención, pudiendo utilizarse a nivel orientativo. Sin embargo, el beneficio potencial sigue estando ahí, esperando a ser aprovechado a través de modelos que consigan una mayor precisión y, teniendo en cuenta el momento actual del proyecto, los resultados obtenidos motivan su continuación y la aceptación de nuevos retos como el desarrollo de modelos que puedan trabajar con múltiples mecanismos de degradación y condiciones de operación.

CONCLUSIONES

Los avances conseguidos en el proyecto de investigación respaldan la validez del enfoque propuesto para la mejora de los planes de mantenimiento y la gestión de vida de las CCNN en el marco de su OLP. Entre las aportaciones del proyecto, destacan el metamodelo para estimación del riesgo considerando explícitamente el efecto de los intervalos de prueba a equipos en espera y la metodología para desarrollar modelos basados en la condición expuesta en el caso de aplicación.

En el caso de aplicación, se observa que es posible generar criterios de actuación a partir del seguimiento de las variables de condición monitorizadas. Aunque la precisión de modelo de regresión todavía no es muy elevada, permite predecir el momento en el que debería de realizarse el mantenimiento ofreciendo la posibilidad de anticiparse al fallo y realizar una planificación óptima del mantenimiento. Como trabajo futuro, se prevé el uso de técnicas más complejas y sofisticadas de aprendizaje automático que permitan afrontar el problema de la diagnosis de diferentes causas de fallo y contribuyan de manera significativa a mejorar la detección de tendencias de degradación y a incrementar la precisión y robustez de las predicciones, avanzando hacia el cumplimiento de los objetivos planteados en el proyecto.

REFERENCIAS

- [1] United States Nuclear Regulatory Commission. (2023). NUREG-2261: Artificial intelligence strategic plan, fiscal years 2023-2027. U.S. NRC.
- [2] International Atomic Energy Agency. (2023). IGALL – GNSSN home. <https://gnssn.iaea.org>
- [3] Electric Power Research Institute. (2019). Quick guide: Continuous online monitoring (COLM).
- [4] Navarro, E., Martón, I., Sánchez, A.I., & Martorell, S. (2026). Development of surrogate models in probabilistic risk assessment accounting explicitly for the effect of surveillance test intervals. Reliability Engineering and System Safety, 268, 112015. <https://doi.org/10.1016/j.ress.2025.112015>
- [5] Navarro, E., Martón, I., Sánchez, A.I., & Martorell, S.

(2025). Risk modeling and optimization using machine learning algorithms for PSA applications. In Proceedings of the 35th European Safety and Reliability Conference (ESREL 2025) and the 33rd Society for Risk Analysis Europe Conference (SRA-E 2025). Stavanger, Norway. <https://rpsonline.com.sg/proceedings/esrel-sra-e2025/pdf/ESREL-SRA-E2025-P2004.pdf>

[6] NASA Prognostics Data Repository. (2008). Commercial modular aero-propulsion system simulation (C-MAPSS) data set.

[7] Ramasso, E., Saxena, A. (2014). Performance benchmarking and analysis of prognostics methods for C-MAPSS datasets. International Journal of Prognostics

and Health Management, 5(2), 1-15. <https://papers.phmsociety.org/index.php/ijphm/article/view/2236>

[8] Jiang, J. (2022). Mixed Effects Models. In Large sample techniques for statistics (Springer Texts in Statistics). Springer. https://doi.org/10.1007/978-3-030-91695-4_12 ■

AGRADECIMIENTOS

Especial agradecimiento al Consejo de Seguridad Nuclear por la subvención concedida dentro del programa de subvenciones de I+D+i 2023 (SUBV-9 2023).