

## Análisis de política de mantenimiento, con modelo predictivo de Riesgos Proporcionales de Weibull PHM y con modelo preventivo a edad constante, caso de estudio en planta Generación Eléctrica

Martín A. Tusco García

E.mail: [martinmg@gmail.com](mailto:martinmg@gmail.com), Antofagasta-Chile

### Abstract

Este documento presenta el uso de dos técnicas para estimar la intervención preventiva en un activo físico. El caso práctico es una caldera de vapor de alta presión perteneciente a una planta de generación eléctrica en el norte de Chile.

La primera técnica es el modelo para mantenimiento preventivo a edad constante, que consiste modelar una función de Esperanzas de Costo de Mantenimiento en forma heurística basado en indicadores de confiabilidad y con aquello encontrar un abanico de soluciones que ayudan a la toma de decisiones [3] [2].

La segunda técnica que se plantea es la del modelo de riesgos proporcionales de Weibull (Proportional Hazard Model, PHM Weibull), que consiste en un procedimiento híbrido para estimar el riesgo de una falla del equipo sujeto a covariables de monitoreo de condición. Es decir, que la tasa de falla del activo es producto de una tasa de falla de referencia que depende de la edad y además, depende de su salud mostrado en covariables de monitoreo de condición [15] [11]. Esta última técnica nos sirve para la estimación de la confiabilidad condicional, basado por lo propuesto en estudio de Banjevic [7], mediante la metodología Propiedad Producto, en conjunto con lo cursado en el módulo del Magister, sistemas informáticos de mantenimiento [18].

El caso aplicado para el uso de estas dos técnicas es para una caldera de vapor de alta presión, donde el modo de falla principal es la “Rotura de tubo”, y con ello, su variable de monitoreo de condición es la medición de espesor del tubo. Los datos fueron recopilados del campo industrial de la propia planta de energía, lugar donde me desempeño laboralmente.

La herramienta computacional con las que se realizan los cálculos numéricos Weibull PHM, es

lenguaje programación Python, la cual es de código abierto y escrito en un entorno de nube proporcionado por Google-Colaboratory, ya que dispone gran número de librerías de cálculo numérico, gratuitas para la toda la comunidad y de accesible desarrollo para la investigación.

Los resultados para el caso práctico en general muestran que la técnica basada en la minimización de costos, da un tiempo menor a la que se tiene que intervenir en comparación al método Weibull PHM en su estado discreto de mejor condición de salud y con ellos encontrando vida útil remanente (RUL). De lo anterior se deja este ejercicio práctico para la toma de decisión ante la incertidumbre del momento oportuno de intervenir.

Cabe destacar, que la diferencia entre ambas técnicas es que aparte de incluir la edad del activo, es poder pronosticar además basado en la salud, específicamente en una de sus covariable de monitoreo. Ya el siguiente paso es tomar la decisión al momento de intervenir.

### 1. Introducción:

La toma de decisiones en mantenimiento industrial requiere minimizar la incertidumbre sobre el momento óptimo de intervención. Este estudio aplica técnicas predictivas y estocásticas a una caldera de alta presión en una planta de generación eléctrica en Chile, utilizando enfoques basados en confiabilidad y monitoreo de condición.

El objetivo principal es comparar dos enfoques para determinar el tiempo óptimo de intervención: el modelo de mantenimiento preventivo a edad constante y el modelo híbrido Weibull PHM. Este último integra la salud del equipo a través de covariables como el espesor de los tubos.



Figura 1: Fotografía de planta generación eléctrica e intervención correctiva tubos interior caldera

## 2. Metodología

### 2.1 Recopilación y procesamiento de datos

Se estructuraron datos históricos de tiempos de operación y monitoreo de espesores de tubos, obtenidos directamente de la planta. Los datos fueron preprocesados para identificar modos de falla relevantes.




Figura 2: Metodología de resolución propuesta. [Elaboración propia]

### 2.2 Modelos analizados

Mantenimiento preventivo a edad constante: Este modelo emplea una función heurística basada en costos preventivos y correctivos para determinar la frecuencia óptima de intervención [3].

$$C_{TM} = \frac{C_P \cdot R(tp) + C_E \cdot [1 - R(tp)]}{MTBM_{tp} + MTTR_{tp}}$$

- $C_{TM}$  : Costo de mantenimiento por unidad de tiempo
- $C_P$  : Costo de una intervención preventiva
- $C_E$  : Costo de una intervención de emergencia
- $R(tp)$  : Confiabilidad en el instante “tp”
- $MTBM_{tp}$  : Esperanza de tiempo entre intervenciones
- $MTTR_{tp}$  : Esperanza de tiempo de reemplazo

Modelo Weibull PHM: Este modelo híbrido combina la edad del activo con su salud, considerando covariables de monitoreo mediante algoritmos como K-means para segmentación de estados y la Propiedad Producto para estimar confiabilidad condicional [15].

$$\lambda(t, z(t)) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} \cdot \exp^{\sum_{i=1}^n y_i z_i(t)}$$

### 2.3 Herramientas computacionales

Se utilizó Python para cálculos iterativos, análisis de Markov y estimaciones estadísticas, lo que permitió manejar grandes volúmenes de datos y realizar simulaciones precisas en la nube con Google Colab.

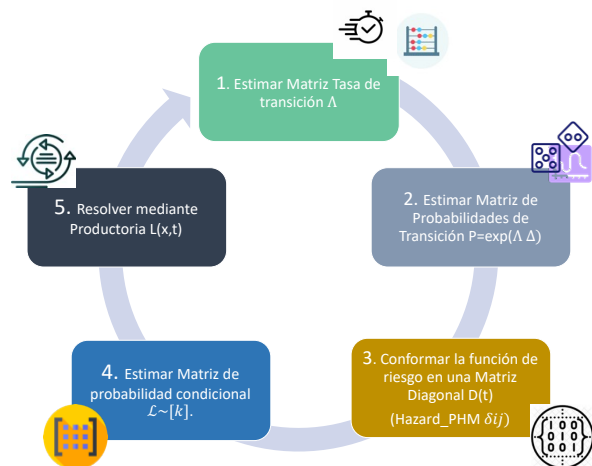


Figura 3: Diagrama resumen del procedimiento Propiedad Producto [18]

### Paso 1. Estimar la matriz de tasa de Transición.

Con el modelo de Markov, se deben definir los estados de funcionamiento de acuerdo al caso de estudio, que van desde una buena operación a una mala operación, posterior se realiza el cálculo de la matriz de transición de estados.

Teniendo la medición de la variable de condición en el tiempo, se procede a discretizar en rangos, estos rangos les llamamos Estados. Es donde la covariable realiza el cambio de un estado al otro en el tiempo. Se logra contando los cambios de estados y agregando el cambio estado (discreto). Aparecen valores negativos en aquella matriz  $\Lambda$ , es la suma con signo negativo en la diagonal, esto para que cada fila sea cero. Esto porque sirve para el siguiente paso donde se calculará la matriz de probabilidades de transición.

$$\check{\lambda}_{ij} = \frac{n_{ij}^{(l)}}{A_i}, \quad i \neq j, \quad \check{\lambda}_{ij} = -\sum_{i \neq j} \lambda_{ij}, \quad \Lambda = [\lambda_{ij}(t)]$$

Donde  $\check{\lambda}_{ij}$  son los componentes de la matriz de tasa de transición de estados  $\Lambda$ ,  $n_{ij}$  el contador de los cambios de los estados de las covariables  $Z(t)$ , y  $A_i$  es el contador de tiempo que el activo permaneció en estado  $i$ .

### Paso 2. Estimar matriz de probabilidades de transición.

$$P^{(l)}(x) = \exp(\Lambda^{(l)}x) = \sum_{i=0}^{\infty} \frac{(\Lambda^{(l)}x)^i}{i!}$$

De aquí se debe realizar la exponencial matricial de la matriz de tasa de transición, con esto se llega a la matriz de probabilidades de transición. Es decir, basado en Markov discreto, se definen la probabilidad de pasar de un estado al siguiente. Donde  $\exp(\Lambda\Delta)$  es la matriz de probabilidades de transición de estados, que se calcula de la forma:

$$\exp(\Lambda\Delta)_{ij} = \check{\lambda}_{ij}\Delta - 1, \quad i \neq j, \quad \exp(\Lambda\Delta)_{ij} = \check{\lambda}_{ij}\Delta$$

### Paso 3. Estimar la matriz $D(t)$ .

Este será un paso intermedio, para conformar la función de riesgo  $h(t)$  en una matriz diagonal.

$$D(t) = \left[ \left( \frac{\beta}{\alpha} \cdot \left( \frac{t}{\alpha} \right)^{\beta-1} \cdot e^{\sum_i \gamma_i \cdot Z_i(t)} \right) \cdot \delta_{ij} \right]$$

### Paso 4. Cálculo general de la Matriz de confiabilidad condicional. [7]

Posteriormente, se encuentran los parámetros necesarios para el cálculo de la confiabilidad condicional, como lo es el tiempo de inicio ( $k\Delta$ ), tiempo de fin ( $m\Delta$ ), la sensibilidad ( $\Delta$ ) y el salto temporal. Definir el delta es clave para ver la precisión del cálculo. Esto tiene un costo iteraciones computacional entre más pequeño el delta. Con esto es posible calcular la integral de la ecuación:

$$\mathcal{L}_z[k] = \exp \left[ \left( \frac{\Delta}{\alpha} \right)^{\beta} (k^{\beta} - (k+1)^{\beta}) \exp(\gamma \cdot \text{estado}(i)) \right] \exp(\Lambda\Delta)$$

De la expresión anterior, el paper considera avanzar en forma de productoria con el paso 5.

### Paso 5. Estimación de la matriz de probabilidad condicional. Y cálculo de la confiabilidad condicional.

Para calcular cualquier forma de la función confiabilidad descrita en [7], se debe calcular la función  $L_{ij}(x, t)$  y se define la matriz  $\mathcal{L}_{ij}(x, t) = [L_{ij}(x, t)]$ .

Luego, el cálculo de la probabilidad condicional queda determinado como el producto de la confiabilidad condicional de cada estados intervalos de tiempo definidos.

$$\mathcal{L}(k\Delta, m\Delta) = \prod_{i=k}^{m-1} \tilde{\mathcal{L}}[i]$$

Después, calculamos la matriz de probabilidad condicional  $\mathcal{L}(k\Delta, m\Delta)$  mediante la propiedad

producto vista en [7], que luego, al sumar cada fila se obtiene la confiabilidad condicional, donde la fila  $i$ -ésima representa la confiabilidad del estado  $i$ . Al realizar una integración numérica de la curva de confiabilidad condicional se obtiene la vida útil remanente. Para abordar este procedimiento se usa las herramientas computacional Lenguaje de programación Python, en ambiente Google Colaboratory.

### 3. Resultados y discusión:

Los resultados clave se resumen a continuación:

#### Modelo a edad constante:

Tiempo óptimo de intervención: 3.372 horas.

Método simple basado en costos.

#### Modelo Weibull PHM (una covariable):

Tiempo de intervención: 3.752 horas (estado inicial óptimo).

Aumenta la disponibilidad operativa al considerar la salud del activo.




Figura 4: Resultado Confiabilidad condicional, para una covariable,  $\Delta=10$

#### Modelo Weibull PHM (cuatro covariables):

Tiempo de intervención: 4.384 horas (estado inicial óptimo).

Se procede a trabajar con más de una covariable es decir cuatro sectores de la caldera: Pared Delantera, trasera, lateral derecha y lateral izquierda. Para comenzar se determinaron los estados de funcionamiento a partir del método de agrupamiento K-means, lo cual requiere la

normalización de las covariables a estudiar, realizándose de la forma: [19]

$$Z(t)_{equivalente} = \sum_{i=0}^n \frac{z(t)_i \gamma_i}{Z(t)_{imax}}$$

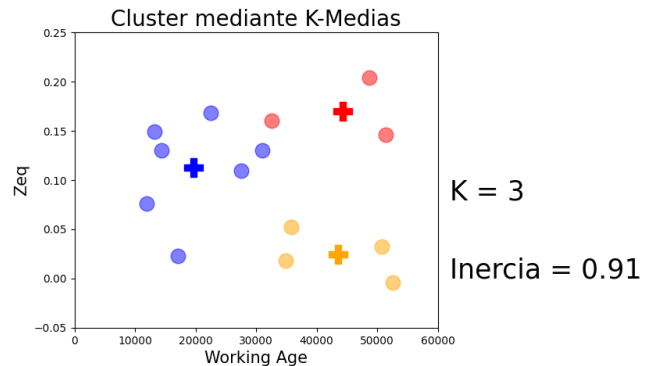


Figura 5: Resultado de centroides y grupos clusters. [Elaboración propia]




Figura 6: Resultado de Confiabilidad Condicional, con cuatro estados,  $\Delta=10$

Mejora la precisión de estimación al incorporar múltiples variables de monitoreo.

La comparación evidencia que el modelo Weibull PHM con covariables permite ajustar mejor las políticas de mantenimiento al estado real del activo, reduciendo intervenciones innecesarias y maximizando la confiabilidad.

Método		Política de intervención (horas)			
Edad	Mtto Preventivo a edad constante	3.372			
	PHM de 1 covariable	Estado 0	Estado 1	Estado 2	
Edad y Salud	PHM de 4 covariable	4.384,41	2.640,88	2.388,06	1.871,51

Tabla 1: Resumen de resultados Métodos de Políticas de Mantenimiento




Figura 4: Resultados de Política intervención, estado 0 de la(s) covariable(s)

#### 4. Conclusiones

La integración de covariables en modelos predictivos proporciona mayor precisión en la estimación del momento óptimo de intervención, mejorando la disponibilidad y reduciendo costos operativos.

El modelo Weibull PHM con múltiples covariables es especialmente efectivo para activos con monitoreo continuo, ya que ajusta dinámicamente la confiabilidad según la salud del equipo.

Se recomienda implementar sistemas de captura de datos estructurados y capacitar al personal en el uso de herramientas predictivas como Python para garantizar la actualización y efectividad de estos modelos.

#### Recomendaciones y Propuestas:

Esta metodología nos da un panorama de posponer y anticipar sus reemplazos. Con ello cuantificarlo, agregando valor, mediante la disponibilidad de la planta generadora antes de ejecutar la intervención.

- Las paradas de planta son algo extensas, y se pudiera aprovechar la planificación de intervención de sus otros sistemas auxiliares de producción. Es recomendable entonces

definir el equipo de nivel jerárquico crítico de la planta de producción.

- Se puede considerar agregar al modelo Weibull PHM para este caso práctico, con una covariable adicional que sería la temperatura del metal del tubo de caldera categorizado por su sector. Esto a sugerencia del juicio de expertos en la industria de generación.
- En próximos trabajos, realizar una sensibilidad de los pesos  $g_i$ , revisando el comportamiento de las curvas de Confiabilidad condicional, nos daría como influye esta ponderación para el análisis.
- El lenguaje abierto de programación, Python, permitió realizar las cientos de iteraciones que conlleva el Método de Propiedad Producto. Además, su uso en el algoritmo de K-Means de Machine Learning, posee las librerías que reducen bastante la carga computacional. Este algoritmo ayudó a abordar el caso cuando se tiene más de una covariable de monitoreo.

#### Bibliografía

- [1] Manual O&M de Planta Generación de Lecho Fluidizado. Parque generación del Norte de Chile.
- [2] Magister en Gestión de Activos y Mantenimiento, Módulo Mantenimiento preventivo cíclico. Universidad Federico Santa María, versión n°18.
- [3] Arata, Adolfo (ed.), “Manual de gestión de Activos y Mantenimiento”, Santiago: RIL editores, 2005.
- [4] Naaman Gurvitz, Clockwork Solutions. Why PHM? Incorporating Covariates in Weibull Analysis.  
<http://www.omdec.com/moxie/Technical/Reliability/why-phm-incorporating-cov.shtml>



[5] Sigüenza G., Pronóstico y determinación de vida útil remanente. Julio 2017.

[6] Nima Gorjian, Yong Sun, Remaining Useful Life Prediction of Rotating Equipment Using Covariate-based Hazard Models - Industry Applications. BHP Billiton – Olympic Dam, PO Box 150, Roxby Downs, SA 5725, Australia.

[7] D. Banjevic y A. K. S. Jardine. “Calculation of reliability function and remaining useful life for a Markov failure time process”.

[8] Nima Gorjian, Asset health prediction using the explicit hazard model. Queensland University of Technology, 2012.

[9] Nima Gorjian, Murthy Mittinty, The Explicit Hazard Model – Part 2: Applications. IEEE, Prognostics & System Health Management Conference, 1214 January 2010, University of Macau, Macau, China. (In Press).

[10] John Fox, Logit and Probit Models For Dichotomous Data, lectures notes 2014.

[11] A. K. S. Jardine, P. M. Anderson and D. S. Mann. “Application of the Weibull Proportional Hazards Model to Aircraft and Marine Engine Failure Data”. Department of Engineering Management, Royal Military College of Canada.

[12] Arancibia Fuentes, Javier. Tesis “Análisis de confiabilidad condicional y vida remanente esperada en paneles solares fotovoltaicos para la aplicación de modelo de mantenimiento basado en condición.”, mayo 2019.

[13] Huamin Liu, Viliam Makis. Cutting-Tool Reliability Assessment in Variable Machining Conditions. University de Toronto.

[14] Zhigang Tian, Haitao Liao, Condition based maintenance optimization for multi-component systems using proportional hazards model. Concordia Institute for Information Systems Engineering, Concordia University

[15] Andrew K. S. Jardine & Albert H. C. Tsang. Libro “Maintenance, Replacement, and Reliability”. Segunda Edición.

[16] Artículo “Calculando la Frecuencia Optima de Mantenimiento o Reemplazo Preventivo: Caso de estudio basado en método y normas”. Predictiva21.

[17] Andrew Jardine, Albert Tsang. Libro “Maintenance and Replacement and Reliability, theory and applications”. Second edition.

[18] D. Godoy. Calculation of Reliability Function for a Markov Failure Time Process using Proportional Hazards Model. Modelos Predictivos, Magister Gestión de Activos y Mantenimiento. Universidad Federico Santa María

[19] Celedón C. y D. Godoy. Tesis “Análisis de Política de Mantenimiento Predictivo para Transformadores de Poder”. Universidad Federico Santa María

[20] Hamza Ayar, Hasna Nhaila and M El Jhaili, Electrical Power Transformer Modeling and Simulation for the Implementation of a Predictive Maintenance Approach. May 24 2022.

[21] Youguo Li, Haiyan Wu. A Clustering Method Based on K-Means Algorithm. (2012) , <https://www.sciencedirect.com/science/article/pii/S1875389212006220>.

[22] Álvaro Hayek. Análisis de datos con Python en salud y deporte. Universidad de la Laguna, Tenerife.

[23] Aprende Machine Learning en español. K-Means en Python paso a paso. Disponible en: <https://www.aprendemachinelearning.com/k-means-en-python-paso-a-paso/>

[24] Sergio Zuñiga. Introducción a la optimización usando Excel. Universidad Católica del norte, Coquimbo.

[25] H. Ji, J. Zhang, Z. Liu, G. Liang, and H. Zhao, “Optimal maintenance decision of power transformers,” in 2010 International Conference on Electrical and Control Engineering, 2010, pp. 3941–3944.

[26]. M. Tusco 2022, Tutorial: “Python, caso práctico PHM Confiabilidad condicional”. Método propiedad producto. <https://www.youtube.com/watch?v=Ys2qiaKNHt4&t=160s>.