


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS
VALPARAÍSO - CHILE



**OPTIMIZACIÓN DEL TIEMPO DE INSPECCIÓN EN UNA
POLÍTICA DE MANTENIMIENTO PREVENTIVO, BAJO UN
ENFOQUE ESTOCÁSTICO**

TRAICY LORENA PONTIVO TORRES

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA
INDUSTRIAL Y AL TÍTULO DE INGENIERA CIVIL INDUSTRIAL

PROFESOR TUTOR : Dr. PABLO A. VIVEROS GUNCKEL
PROFESOR CORREFERENTE INTERNO : Dr. FREDY A. KRISTJANPOLLER RODRÍGUEZ

JULIO 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título; Tesis de Postgrado;

Título del trabajo: OPTIMIZACIÓN DEL TIEMPO DE INSPECCIÓN EN UNA POLÍTICA DE MANTENIMIENTO PREVENTIVO, BAJO UN ENFOQUE ESTOCÁSTICO

Nombre del candidato(a): Traicy Lorena Pontivo Torres

Carrera / Grado: Magister en Ciencias de la Ingeniería Industrial

Campus: Casa Central Valparaíso; **Departamento:** Departamento de Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Pablo Viveros, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

6 meses; 12 meses; 2 años; 3 años; 5 años; 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):
No aplica.

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 30/06/2025

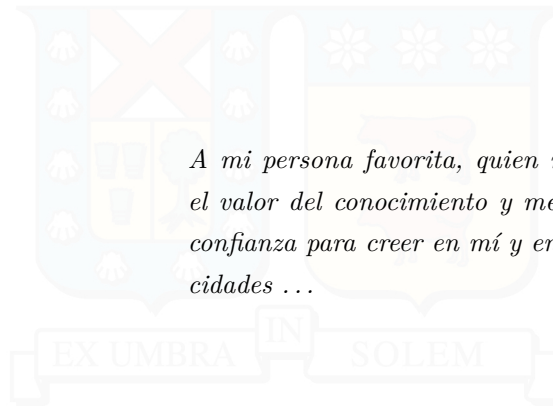
; Firma:

Estudiante o Candidato(a):

Fecha: 30/06/2025

; Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



*A mi persona favorita, quien me enseñó
el valor del conocimiento y me brindó la
confianza para creer en mí y en mis capa-
cidades ...*

AGRADECIMIENTOS

Este trabajo no habría sido posible sin el cariño, el apoyo y la compañía de muchas personas especiales, a quienes quiero agradecer sinceramente por hacer de este proceso algo mucho más ameno.

Primero, a mi familia, mis papás y mis hermanas Yaritza y Aisa, por estar siempre ahí, acompañándome en cada paso. Su apoyo y compañía han sido un pilar fundamental durante todos estos años.

A mis niños —Daniel, Daniela, Gonzalo y Gian— gracias por la amistad, las largas jornadas de estudio y por estar presentes a lo largo de todo este camino, de una forma u otra. Ustedes hicieron que todo esto fuera más llevadero y, sobre todo, mucho más entretenido.

A Victoria y Mauricio, que en los primeros años de universidad me acompañaron y ayudaron a adaptarme a la nueva ciudad. Gracias por sus indicaciones, por las compras en el supermercado y, por supuesto, por esos paseítos que ayudaban a distraerme.

Al querido team EC2G —Valentina, Constanza, Javi, Max, Laura, Goli, Javier, Martín, Felipe, Amanda y Carlos— por cada almuerzo compartido, las innumerables celebraciones, pizzas, completos, empanaditas y muchos otros momentos que hicieron de mi paso por el magíster algo mucho más llevadero.

Al team piscina —Maxi, Pablo, Stefi, Matías, Gustavo, Javiera, Branko, Javier, Sofía y Naty— gracias por las risas, las conversaciones y esa energía positiva que siempre traían consigo. En especial, a Vale Flores, mi compañera de magíster, por esas pausas necesarias y las conversaciones en la oficina que ayudaban a refrescar la mente y continuar con el trabajo de mejor forma.

A Nicolás, mi gran compañero y persona especial, por haberme impulsado, desde que nos conocimos a probar cosas nuevas, a confiar en mí y a tomar decisiones importantes, como postular al magíster o atreverme con mis primeras ayudantías. Tu apoyo ha sido clave desde el primer día, y agradezco tenerte a mi lado en cada momento de estos últimos años.

Y, por último, a mi abuelo, mi Tunita, mi persona favorita en el mundo. Aunque ya no esté conmigo, su cariño, sus enseñanzas y su confianza en mí me acompañan siempre. Desde pequeña me motivó a aprender y a creer en mí, y ese impulso me trajo hasta aquí.

Gracias a todos y todas por ser parte de este viaje.

RESUMEN EJECUTIVO

El mantenimiento preventivo es una estrategia fundamental para garantizar la confiabilidad de los sistemas, reducir costos operacionales y evitar fallos imprevistos. Este trabajo se centra en la optimización de la frecuencia de inspección en sistemas de mantenimiento preventivo, utilizando un enfoque basado en simulación estocástica. A través de la implementación de simulaciones de Monte Carlo, se evalúan distintas frecuencias de inspección para minimizar los costos asociados, considerando la incertidumbre inherente en los sistemas y sus parámetros.

Para una mejor comprensión del comportamiento de los costos bajo incertidumbre, se introducen métricas de riesgo como el Valor en Riesgo (VaR) y el Valor en Riesgo Condicional (CVaR). Estas métricas permiten evaluar no solo el costo esperado, sino también la variabilidad y la exposición a eventos extremos, que podrían generar costos elevados y no planificados. Los resultados muestran que, aunque las frecuencias de inspección más altas tienden a reducir el costo esperado, las métricas de riesgo sugieren que una frecuencia de inspección más baja puede ser más beneficiosa en escenarios con alta incertidumbre, al minimizar la exposición a riesgos extremos.

Además, se realiza un análisis de la semidesviación superior, lo que permite identificar las frecuencias de inspección que ofrecen un equilibrio entre el costo esperado y la variabilidad de los costos. Los resultados demuestran que, al considerar estas métricas de riesgo, es posible encontrar una frecuencia óptima de inspección que no solo sea económicamente favorable, sino también robusta frente a los riesgos y la incertidumbre.

Este enfoque proporciona una metodología innovadora para optimizar políticas de mantenimiento preventivo en condiciones de incertidumbre, ofreciendo una herramienta valiosa para la toma de decisiones en industrias que dependen de la confiabilidad y disponibilidad de sus sistemas. A través de este análisis, se busca no solo minimizar los costos directos de mantenimiento, sino también reducir los riesgos asociados con fallos inesperados, logrando una solución más robusta y eficiente.

Palabras clave: Mantenimiento preventivo, simulación estocástica, frecuencia de inspección, métricas de riesgo, Valor en Riesgo (VaR), Valor en Riesgo Condicional (CVaR), semidesviación superior.

ABSTRACT

Preventive maintenance is a fundamental strategy for ensuring system reliability, reducing operational costs, and preventing unexpected failures. This work focuses on the optimization of inspection frequency in preventive maintenance systems using a stochastic simulation approach. By implementing Monte Carlo simulations, different inspection frequencies are evaluated to minimize associated costs, considering the uncertainty inherent in system parameters.

To better understand the behavior of costs under uncertainty, risk metrics such as Value at Risk (VaR) and Conditional Value at Risk (CVaR) are introduced. These metrics allow for the assessment of not only expected costs but also variability and exposure to extreme cost events, which could result in high and unplanned costs. The results show that although higher inspection frequencies tend to reduce expected costs, risk metrics suggest that a lower inspection frequency may be more beneficial in high-uncertainty scenarios by minimizing exposure to extreme risks.

Furthermore, an analysis of the upper semideviation is conducted to identify inspection frequencies that strike a balance between expected costs and cost variability. The results demonstrate that, by considering these risk metrics, it is possible to find an optimal inspection frequency that is not only economically favorable but also robust against risks and uncertainty.

This approach provides an innovative methodology for optimizing preventive maintenance policies under uncertainty, offering a valuable tool for decision-making in industries that depend on the reliability and availability of their systems. Through this analysis, the aim is not only to minimize direct maintenance costs but also to reduce the risks associated with unexpected failures, achieving a more robust and efficient solution.

Keywords: Preventive maintenance, stochastic simulation, inspection frequency, risk metrics, Value at Risk (VaR), Conditional Value at Risk (CVaR), upper semideviation.

Índice de Contenidos

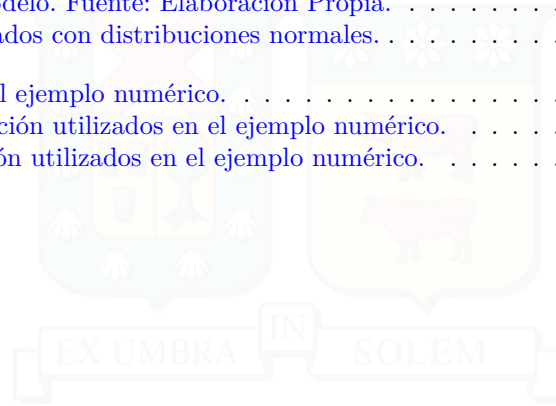
1. Introducción	1
2. Problema de Investigación	3
3. Objetivos	6
3.1. Objetivo General	6
3.2. Objetivos específicos	6
4. Marco teórico	7
4.1. Introducción al Mantenimiento Industrial	7
4.1.1. Evolución Histórica del Mantenimiento Industrial	7
4.1.2. Caracterización de la Gestión Moderna del Mantenimiento Industrial	8
4.2. Tipos de Mantenimiento	9
4.2.1. Mantenimiento Correctivo	9
4.2.2. Mantenimiento Preventivo	9
4.2.3. Mantenimiento Predictivo	10
4.3. Políticas de Mantenimiento Preventivo	10
4.3.1. Política de Mantenimiento Basado en el tiempo	10
4.3.2. Política de Mantenimiento Basado en la Condición	12
4.4. Frecuencia de Inspección en Mantenimiento	13
4.5. Uso de la Distribución Weibull en Mantenimiento	14
4.5.1. Función de Densidad de Probabilidad (PDF)	14
4.5.2. Función de Confiabilidad	14
4.5.3. Tasa de Falla (Hazard Rate)	15
4.6. Simulación de MonteCarlo Aplicada en Mantenimiento	16
4.6.1. Muestreo de Números Aleatorios	16
4.6.2. Aplicación en Mantenimiento	17
4.7. Evaluación de Desempeño y Métricas en Mantenimiento	18
4.7.1. Indicadores Clave de Desempeño en Mantenimiento	18
4.7.1.1. KPIs de Costo de Mantenimiento	19
4.7.1.2. KPIs de Actividades de Mantenimiento	20
4.7.1.3. KPIs de Rendimiento del Mantenimiento	20
4.8. Evaluación del Riesgo en Mantenimiento	20
4.8.1. Conditional Value at Risk (CVaR)	21
4.8.2. Análisis de Dominancia	22
4.8.3. Análisis de Sensibilidad	23
5. Estado del Arte	25
6. Metodología	28
7. Formulación del Modelo	30
7.1. Metodología General	30
7.2. Lógica de Simulación	32
7.3. Parámetros del Modelo	33
7.4. Determinación de Parámetros Estocásticos	35
7.5. Criterio de Optimización	36
7.6. Matriz de Probabilidad de Estado de Deterioro (DSPM)	37

7.6.1. Fuentes para la Obtención de la DSPM	38
7.6.2. Futuro Desarrollo de la DSPM	39
7.7. Tiempo hasta la Falla Simulado (STTF)	39
8. Aplicación Numérica	41
8.1. Especificaciones del Ejemplo Numérico	41
8.2. Parámetros Estocásticos del Problema	42
9. Resultados	44
9.1. Métricas de Riesgo	46
9.2. Análisis de Sensibilidad	48
10. Discusiones y conclusiones	51
10.1. Trabajo Futuro	52
Bibliografía	54



Índice de Tablas

7.1. Parámetros del Modelo. Fuente: Elaboración Propia.	34
7.2. Parámetros modelados con distribuciones normales.	35
8.1. Especificaciones del ejemplo numérico.	41
8.2. Tiempos de reparación utilizados en el ejemplo numérico.	42
8.3. Costos de reparación utilizados en el ejemplo numérico.	42



Índice de Figuras

2.1. Ilustración de la política de mantenimiento. Fuente: Elaboración Propia	3
2.2. Casos posibles al realizar una inspección. Fuente: Elaboración Propia	4
2.3. Ejemplo de trayectoria de operación del componente. Fuente: Elaboración Propia	4
4.1. Curva de bañera. Fuente: [1]	11
4.2. Proceso general del TBM. Fuente: [1]	11
7.1. Desarrollo del Modelo de Simulación. Fuente: Elaboración Propia.	30
7.2. Diagrama de flujo de proceso para el modelo de simulación estocástica. Fuente: Elaboración propia.	33
9.1. Frecuencia de Inspección Óptima basada en el Valor Esperado.	44
9.2. Comportamiento de los costos en función de la frecuencia de inspección.	45
9.3. Cantidad de intervenciones en función de la frecuencia de inspección.	45
9.4. Gráfico de VaR y CVaR para cada frecuencia de inspección.	47
9.5. Análisis de semidesviación y dominancia de semidesviación vs costo esperado.	48
9.6. Resultados Análisis de Sensibilidad Global	49

1 | Introducción

El mantenimiento en entornos industriales es una práctica esencial para garantizar la operación continua y eficiente de equipos y sistemas [2]. Este conjunto de actividades no solo busca prevenir fallos y prolongar la vida útil de los equipos, sino también optimizar su rendimiento y reducir costos a largo plazo. Dentro de las estrategias de mantenimiento, el mantenimiento preventivo se destaca por su enfoque proactivo, interviniendo antes de que las fallas ocurran, lo cual es crucial para evitar interrupciones en la producción y asegurar la disponibilidad de los equipos [3] [4].

El mantenimiento preventivo incluye una serie de tareas programadas, como inspecciones, ajustes, reparaciones y reemplazos de componentes, que se realizan en intervalos predeterminados. La frecuencia con la que se llevan a cabo estas inspecciones es un factor determinante en la eficacia del mantenimiento preventivo, ya que una frecuencia de inspección adecuada permite detectar y corregir problemas potenciales antes de que se conviertan en fallas mayores. Sin embargo, establecer esta frecuencia no es una tarea sencilla, debido a que se deben considerar diversos factores, como el tipo de equipo, las condiciones de operación, los costos asociados al mantenimiento y las posibles consecuencias de fallas inesperadas.

Determinar la frecuencia óptima de inspección es un desafío significativo porque implica encontrar un equilibrio entre inspecciones frecuentes, que pueden aumentar los costos operativos y reducir la productividad, e inspecciones esporádicas, que pueden resultar en fallos inesperados y tiempos de inactividad no planificados [5]. En contextos donde los costos de fallos no son elevados, un enfoque basado en intervalos fijos puede ser suficiente y más rentable. Sin embargo, en entornos donde la confiabilidad y la disponibilidad del equipo son críticas, se necesita un enfoque más sofisticado.

En este contexto, un enfoque estocástico resulta particularmente útil pues, diferencia de los métodos determinísticos que asumen tiempos de falla y reparación fijos, los modelos estocásticos consideran la variabilidad inherente en estos tiempos [6]. Esto permite desarrollar estrategias de mantenimiento más realistas y adaptativas, que pueden ajustarse dinámicamente a las condiciones operativas y a la evolución del estado de los equipos. Los modelos estocásticos permiten modelar y gestionar la incertidumbre, ofreciendo una solución robusta y flexible que puede adaptarse a diversas condiciones operativas y lograr un equilibrio óptimo entre costos y disponibilidad del equipo.

Dado lo anterior, esta tesis tiene como objetivo desarrollar una metodología que, mediante la simulación y el uso de parámetros estocásticos, permita determinar la frecuencia óptima de inspección dentro de una política de mantenimiento preventivo. La hipótesis central de esta investigación es que la implementación de un modelo estocástico para determinar la frecuencia de inspección en mantenimiento preventivo optimizará los costos y mejorará la disponibilidad

de los equipos en comparación con los métodos tradicionales. Se espera que este enfoque permita identificar patrones y tendencias en los resultados, facilitando la toma de decisiones informadas.

Este manuscrito se enmarca dentro del trabajo de tesis de la autora, que le permitirá obtener el título de *Ingeniera Civil Industrial*, junto con el grado de *Magíster en Ciencias de la Ingeniería Industrial* de la Universidad Técnica Federico Santa María.



2 | Problema de Investigación

La problemática puede formalizarse considerando un componente crítico que debe ser inspeccionado periódicamente a lo largo de un horizonte de planificación T , medido en unidades de tiempo (u.t.), donde la frecuencia o periodicidad de inspección t_i es ajustable, y el reto consiste en determinar su valor óptimo. Cada inspección conlleva un costo $C_{\text{inspection}}$, mientras que cada intervención preventiva implica un costo $C_{\text{maintenance}}$, el cual incluye gastos de reparación, mano de obra, repuestos y posibles pérdidas operativas. En caso de que ocurra una falla, se incurre en un costo de falla C_{failure} , que también abarca costos de reparación o mano de obra, repuestos y pérdidas operativas, pero a un mayor costo en comparación con el mantenimiento preventivo, debido a las características del mantenimiento correctivo.

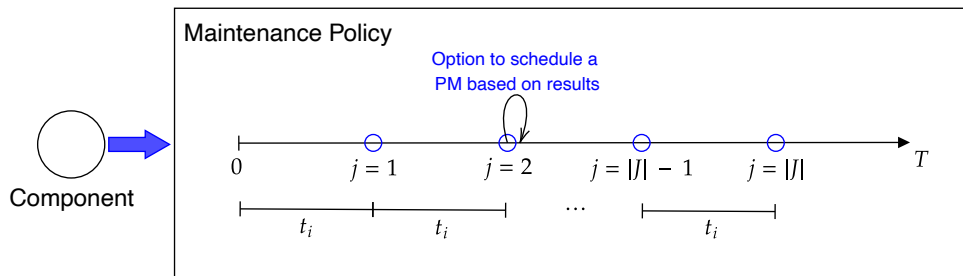


Figura 2.1: Ilustración de la política de mantenimiento. Fuente: Elaboración Propia

En cada inspección j , el estado del componente puede clasificarse en uno de tres casos, los cuales se ilustran en la [Figura 2.1](#) y se describen a continuación:

- (I) **Sin signos de deterioro:** El componente no presenta indicios de deterioro significativo tras la inspección, lo que permite continuar su operación sin necesidad de intervención, al menos hasta la próxima inspección programada o hasta que ocurra una falla inesperada.
- (II) **Con signos de deterioro:** La inspección revela un nivel de deterioro considerable en el componente, lo que desencadena una acción de mantenimiento preventivo para corregir el problema y evitar una posible falla.
- (III) **Falla antes de la inspección:** El componente sufre una falla antes de que la inspección programada se lleve a cabo. Este es el caso más crítico, ya que requiere una reparación correctiva, con los consecuentes costos y tiempos de inactividad asociados.

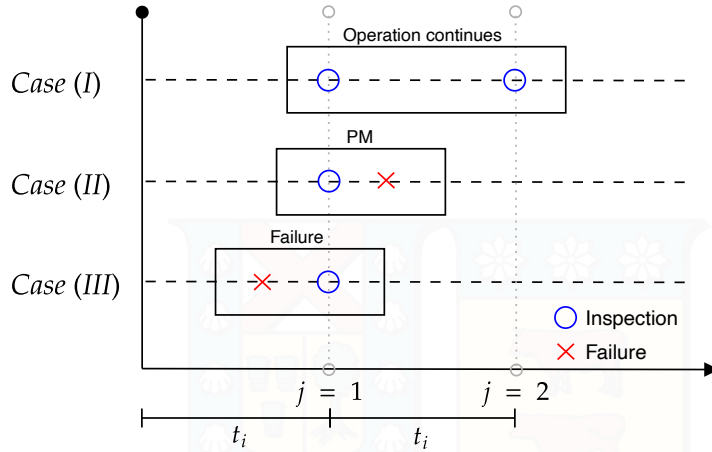


Figura 2.2: Casos posibles al realizar una inspección. Fuente: Elaboración Propia

El nivel de deterioro del componente crítico se clasifica en L niveles, donde $l = \{1, 2, \dots, |L|\}$ representa el índice de cada nivel, y $|L|$ es el número total de niveles de deterioro del componente en análisis. El nivel 1 indica que el equipo está como nuevo, mientras que el nivel $|L|$ representa una falla completa del componente. Además, dependiendo del nivel de deterioro observado, se pueden llevar a cabo M tipos de mantenimiento, donde $m = \{1, 2, \dots, |M|\}$. Estos tipos de mantenimiento se diferencian por la complejidad de la intervención requerida y el costo asociado a los diferentes niveles de deterioro en los que se puede encontrar el equipo. Tras la realización de cualquiera de estos tipos de mantenimiento, el componente retorna a su estado óptimo, es decir, queda como nuevo.

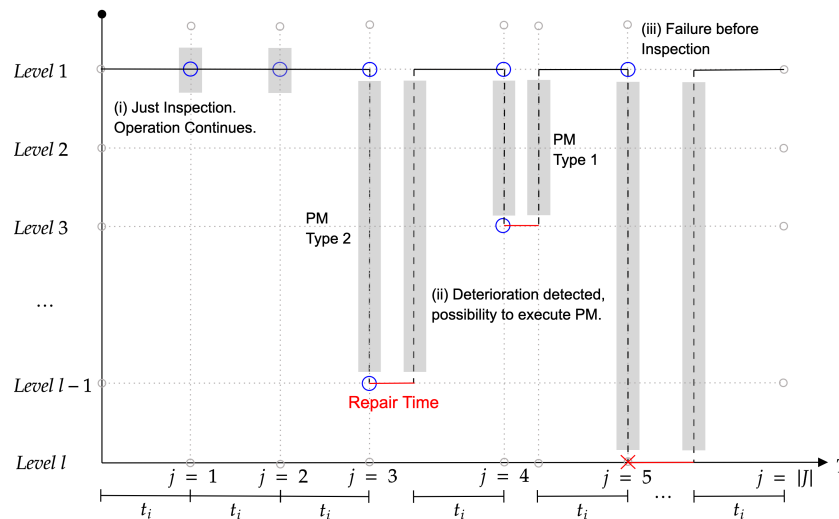


Figura 2.3: Ejemplo de trayectoria de operación del componente. Fuente: Elaboración Propia

A partir de lo anterior, y tal como se ilustra en la [Figura 2.2](#), el componente comienza su ciclo de operación en un estado óptimo (como nuevo) y experimenta un proceso de deterioro

a lo largo de su vida útil. Durante este ciclo, pueden realizarse varias intervenciones de mantenimiento, tanto preventivas como correctivas, las cuales se agrupan en $|K|$ intervenciones totales. Cada intervención k , con $k = \{1, 2, \dots, |K|\}$, puede clasificarse en los diferentes m tipos de mantenimiento dependiendo del caso y el objetivo es ajustar la periodicidad de las inspecciones t_i de manera que se minimice el costo total esperado CT , que incluye los costos de inspección $C_{\text{inspection}}$, los costos de mantenimiento preventivo $C_{\text{maintenance}}$ y los costos asociados a una falla C_{failure} .

Para abordar esta problemática, se propone el desarrollo de un modelo de simulación estocástica que permita capturar la incertidumbre inherente en el proceso de deterioro y fallas del componente. Este enfoque estocástico facilita una evaluación más realista de los escenarios posibles, permitiendo optimizar la periodicidad de inspección bajo condiciones dinámicas. El modelo y su metodología serán descritos en detalle en el [Capítulo 7](#).



3 | Objetivos

3.1 Objetivo General

El objetivo general de este trabajo es desarrollar una metodología basada en un enfoque estocástico que permita determinar la frecuencia óptima de inspección en el contexto de una política de mantenimiento preventivo, con el propósito de minimizar los costos operativos.

3.2 Objetivos específicos

- Realizar una exhaustiva revisión bibliográfica sobre mantenimiento preventivo y enfoques estocásticos, centrándose en investigaciones clave que aborden la optimización de la frecuencia de inspección, para establecer una base sólida y comprender los aspectos fundamentales que se pretenden abordar en este trabajo.
- Identificar y modelar las variables estocásticas clave en el proceso de mantenimiento preventivo, desarrollando modelos probabilísticos que describan el comportamiento de estas variables en distintos escenarios de mantenimiento.
- Desarrollar una metodología basada en un enfoque estocástico que permita determinar la frecuencia óptima de inspección en el contexto de una política de mantenimiento preventivo, utilizando técnicas de simulación para modelar el comportamiento del equipo.
- Aplicar la metodología desarrollada en un caso de estudio para analizar el comportamiento de los costos de mantenimiento, recopilando datos relevantes sobre factores que afectan la frecuencia de inspección y los costos asociados.
- Proponer recomendaciones y directrices para la implementación práctica de la metodología en diferentes contextos industriales, sugiriendo mejoras y futuras líneas de investigación basadas en los resultados obtenidos y las limitaciones encontradas durante el estudio.

4 | Marco teórico

En el marco de esta investigación, resulta fundamental abordar los conceptos primordiales del mantenimiento industrial desde una perspectiva estocástica. Se explorarán en profundidad los fundamentos del mantenimiento, incluyendo definiciones y tipologías diversas. Asimismo, se analizarán las políticas de mantenimiento preventivo y su implementación en distintos sectores industriales. Se otorgará especial énfasis a la frecuencia de inspección en el mantenimiento, abordando su importancia, métodos de determinación y los factores determinantes en su aplicación. Por último, se examinarán los principios esenciales del enfoque estocástico, destacando su aplicación en el modelado probabilístico de equipos, considerando variables como tiempos de falla y costos de mantenimiento.

4.1 Introducción al Mantenimiento Industrial

El mantenimiento industrial juega un papel fundamental en la gestión eficaz de los activos físicos de una empresa. Consiste en prácticas y estrategias implementadas para asegurar que los equipos, maquinaria y sistemas funcionen de manera óptima y confiable durante toda su vida útil [7]. Este campo se centra no sólo en reparar y reemplazar componentes defectuosos, sino también en prevenir fallas mediante inspecciones periódicas y mantenimiento preventivo y predictivo.

4.1.1. Evolución Histórica del Mantenimiento Industrial

John Moubray, en su libro *RCM II: Reliability-centered Maintenance* [8], plantea que desde la década de 1930, la gestión del mantenimiento ha sufrido una serie de cambios que están relacionados esencialmente con la evolución de los activos físicos y los procesos productivos que determinan su funcionamiento. La gestión del mantenimiento se divide en tres generaciones, cada una con sus propias características y expectativas, que se analizan a continuación:

- **Primera Generación:** Esta generación duró desde principios de la década de 1930 hasta la Segunda Guerra Mundial. Se caracterizó principalmente por un bajo grado de mecanización y procesos de producción encadenados, sin que los tiempos de reparación tuvieran un gran impacto en el rendimiento de la producción. Por otro lado, los equipos involucrados generalmente trabajaban con exceso de capacidad, otra condición relevante, para reducir el impacto del mantenimiento en el desempeño de la producción.
- **Segunda Generación:** Esta generación se desarrolló hasta la década de 1980. Respondió a nuevos desafíos ante el nuevo contexto histórico que condujo al fin de la Segunda Guerra Mundial. El proceso productivo se fue mecanizando progresivamente, aumentando el

número y la complejidad de las máquinas implicadas. Esto ha llevado a que los procesos de producción se vuelvan cada vez más dependientes de estas máquinas, y el objetivo de mantenerlas en funcionamiento para aumentar la producción se vuelve cada vez más importante. Dado el aumento de volumen y complejidad antes mencionado, los costos de mantenimiento comenzaron a aumentar rápidamente, lo que requirió planificación y gestión del mantenimiento. Aquí es donde resulta útil aplicar un mantenimiento preventivo, que corresponde a un conjunto de actividades que se planifican y ejecutan periódicamente para reducir el riesgo de fallas no detectadas.

- **Tercera Generación:** Esta generación trae nuevas expectativas y cambios significativos respecto a las prácticas utilizadas en generaciones anteriores a la luz de nuevas investigaciones en esta área. Ahora se cuestiona la relación previamente establecida entre la vida útil del dispositivo y la tasa de fallas y, debido a la tendencia hacia sistemas just-in-time, el impacto del tiempo de inactividad se calificó como más severo. Los sistemas just-in-time se caracterizan por un buffer de almacenamiento reducido, lo que hace que el proceso de producción sea más sensible a fallos y, además, la mayor mecanización de los procesos y su automatización ha aumentado la confiabilidad y disponibilidad de los equipos en indicadores y elementos clave en diversos sectores industriales. Los costos de mantenimiento, por su parte, van en aumento y la proporción de los costos de mantenimiento en los costos totales de una organización también. Por último, pero no menos importante, los eventos de falla que pueden afectar la seguridad y el medio ambiente se han vuelto críticos para el funcionamiento futuro de una organización y, a medida que las expectativas para esta tercera generación han aumentado, han surgido diversas tecnologías para satisfacer estas necesidades.

4.1.2. Caracterización de la Gestión Moderna del Mantenimiento Industrial

Una forma de caracterizar la gestión del mantenimiento considera que un sistema de mantenimiento puede considerarse como un sistema input-output. Los inputs corresponden a la mano de obra, la gestión, las herramientas, los equipos, entre otros y los outputs son los equipos bien configurados y funcionando de buena forma para alcanzar el funcionamiento previsto de la planta. Bajo este enfoque, se establece que las actividades necesarias para que este sistema sea funcional son la planificación del mantenimiento, la organización del mantenimiento y el control del mantenimiento [9].

Otro enfoque [7] indica que la forma de caracterizar la gestión del mantenimiento es considerar dos dimensiones. Por un lado, el proceso asociado a la gestión del mantenimiento, es decir, el curso de acción o la serie de pasos o etapas a seguir con el fin de llevar a cabo correctamente las tareas de mantenimiento, así como su evaluación y su mejora y, por otra parte la identificación del marco de trabajo, vale decir, la estructura que brinda el soporte necesario para llevar a cabo el proceso de mantenimiento .

Siguiendo con el enfoque de Crespo [7], a nivel estratégico, el proceso de mantenimiento contempla desde la determinación del plan de negocios hasta el plan de mantenimiento y, por su parte, el nivel táctico comprende las actividades desde la planificación del mantenimiento hasta la programación.

Por otro lado, el nivel operativo se encarga de la ejecución de las tareas de mantenimiento. A lo largo de este proceso, existe una estructura que le entrega el soporte para su ejecución. Dicha estructura, denominada marco de trabajo del mantenimiento, comprende tres pilares esenciales :

- Pilar Tecnologías de la Información, el cual permite tanto a los gerentes como al personal de producción y de mantenimiento acceder a los datos de los equipos.
- Pilar Ingeniería del Mantenimiento, consistente en el conjunto de técnicas utilizadas a lo largo de las distintas etapas del proceso, por ejemplo Mantenimiento Centrado en la Confiabilidad (RCM).
- Pilar Organizacional, el cual contempla todo el recurso humano relacionado al mantenimiento y a la ejecución de las tareas relacionadas.

4.2 Tipos de Mantenimiento

El mantenimiento industrial se puede clasificar en varios tipos principales, cada uno con enfoques y objetivos específicos para garantizar la disponibilidad y confiabilidad de los activos industriales.

4.2.1. Mantenimiento Correctivo

El mantenimiento correctivo, también conocido como mantenimiento reactivo, se centra en corregir errores y fallas en dispositivos y sistemas tan pronto como ocurren. Este tipo de mantenimiento normalmente se realiza de forma no planificada, en respuesta directa a la detección de problemas operativos o funcionales. Las acciones correctivas pueden variar desde reparaciones simples hasta el reemplazo completo de componentes defectuosos [7].

Aunque el mantenimiento reactivo es eficaz para resolver problemas de inmediato, tiene algunas limitaciones importantes. Por ejemplo, esto puede provocar tiempos de inactividad no planificados, afectar la productividad e incurrir en costos adicionales por reparaciones de emergencia o reemplazo de equipos costosos

4.2.2. Mantenimiento Preventivo

El mantenimiento preventivo se basa en la premisa de realizar intervenciones planificadas y sistemáticas en los equipos antes de que ocurran fallos o averías. El objetivo principal es prevenir la ocurrencia de problemas mediante la aplicación de actividades de inspección, ajuste,

limpieza, lubricación y reemplazo de componentes según un calendario predefinido o criterios establecidos [8].

Existen dos enfoques principales dentro del mantenimiento preventivo [7]:

- Basado en el tiempo: Se programan actividades de mantenimiento en intervalos regulares, como mensualmente o anualmente, independientemente del estado operativo del equipo.
- Basado en la condición: Las decisiones de mantenimiento se basan en la evaluación del estado actual del equipo, utilizando técnicas de monitoreo y diagnóstico para determinar cuándo se requieren intervenciones.

El mantenimiento preventivo ayuda a reducir el riesgo de fallos inesperados, prolongar la vida útil de los activos y optimizar la eficiencia operativa al minimizar los tiempos de inactividad no planificados.

4.2.3. Mantenimiento Predictivo

El mantenimiento predictivo se basa en el monitoreo continuo de parámetros de operación y condiciones de los equipos, utilizando tecnologías avanzadas como sensores, análisis de datos y modelos predictivos. El objetivo es predecir el momento óptimo para realizar intervenciones de mantenimiento, basándose en indicadores tempranos de degradación o falla [10].

Algunos métodos comunes utilizados en el mantenimiento predictivo incluyen el análisis de vibraciones, termografía, análisis de aceite, ultrasonido, entre otros. Estas técnicas permiten identificar problemas potenciales antes de que afecten negativamente la operación del equipo, facilitando intervenciones de mantenimiento planificadas y eficientes.

El mantenimiento predictivo puede resultar en menores costos de mantenimiento, al evitar reparaciones costosas y minimizar los tiempos de inactividad no planificados. Además, optimiza el uso de recursos al programar actividades de mantenimiento solo cuando son necesarias, maximizando la disponibilidad y confiabilidad de los activos industriales.

4.3 Políticas de Mantenimiento Preventivo

El mantenimiento preventivo es fundamental para asegurar la disponibilidad y confiabilidad de los activos industriales, reduciendo el riesgo de fallas no planificadas y optimizando los costos operativos a lo largo de su vida útil [11]. Se pueden implementar diferentes políticas y estrategias, cada una diseñada para maximizar la eficiencia y efectividad del programa de mantenimiento.

4.3.1. Política de Mantenimiento Basado en el tiempo

El mantenimiento basado en tiempo (TBM, por sus siglas en inglés) es una técnica de mantenimiento tradicional que también se conoce como mantenimiento periódico. En el TBM,

las decisiones de mantenimiento (por ejemplo, tiempos/intervalos de reparación preventiva) se determinan basándose en análisis de tiempos de fallos. En otras palabras, la vida útil estimada T de un equipo se calcula en función de los datos de tiempo de fallo o de uso [1].

Alaswad y Xiang [1] plantean que el TBM asume que el comportamiento de falla del equipo es predecible. Esta suposición se basa en las tendencias de tasas de fallas, conocidas como curvas de bañera, que se muestran en la Figura 4.1. Las tendencias de las tasas de fallas pueden dividirse en tres fases: periodo de prueba, vida útil y desgaste. El TBM supone que los equipos experimentan tasas de falla decrecientes al principio de su ciclo de vida (periodo de prueba o mortalidad infantil), seguidas de una tasa de falla casi constante (vida útil). Al final de sus ciclos de vida (desgaste), los equipos experimentan tasas de fallo crecientes.




Figura 4.1: Curva de bañera. Fuente: [1]

El proceso general del TBM se puede presentar en dos pasos, como se muestra en la Figura 4.2. El primer proceso del TBM comienza con el análisis/modelado de los datos de fallo. El propósito básico de este proceso es investigar estadísticamente las características de fallo del equipo basándose en el conjunto de datos de tiempo de fallo recopilados. Una vez recopilado un conjunto de datos de tiempo de fallo, se analiza a través del modelado estadístico/de confiabilidad para identificar las características de fallo del equipo.



Figura 4.2: Proceso general del TBM. Fuente: [1]

El TBM realiza actividades de mantenimiento en base a intervalos de tiempo predefinidos, independientemente del estado real del equipo en ese momento. Aunque esta técnica es simple y fácil de implementar, no siempre resulta óptima en términos de costos y eficiencia operativa, debido a que puede resultar en actividades de mantenimiento innecesarias o en la falta de detección de fallos al ocurrir esto fuera de los intervalos programados.

4.3.2. Política de Mantenimiento Basado en la Condición

La política de mantenimiento basado en la condición se centra en realizar intervenciones de mantenimiento solo cuando sea necesario, basándose en el monitoreo continuo de los parámetros de rendimiento del equipo y las condiciones operativas reales. Este enfoque permite identificar problemas emergentes antes de que afecten negativamente las operaciones y productividad de una respectiva empresa o industria [12].

De acuerdo con Byron Ellis [13] se definen los siguientes aspectos acerca del mantenimiento basado en condición:

- **Objetivos del CBM:** El objetivo principal del CBM es minimizar el costo total de las inspecciones y reparaciones mediante la recolección e interpretación de datos intermitentes o continuos relacionados con la condición operativa de componentes críticos de un activo. De esta manera, se pueden planificar reparaciones basadas en la degradación del activo, en lugar de realizar reparaciones costosas basadas en intervalos de tiempo fijo o enfrentar paradas de emergencia.
- **Requisitos del CBM:** Para la implementación efectiva del CBM, es fundamental contar con el soporte de la gestión, un análisis de datos que permita identificar los puntos de monitoreo más rentables, y una organización de mantenimiento con conocimientos y disciplina. Además, es indispensable contar con un análisis robusto de datos de confiabilidad y de mantenimiento financiero, junto con una comprensión clara de los modos y tasas de fallas, la criticidad de los equipos y los posibles beneficios asociados con diferentes estrategias de mantenimiento.
- **Beneficios del CBM:** El CBM ofrece varios beneficios, entre los que se incluye la capacidad de proporcionar una notificación adecuada sobre fallas inminentes, lo que permite realizar reparaciones planificadas basadas en la degradación del activo. Además de lo anterior, el CBM permite evitar el reemplazo prematuro de componentes, maximizando así su vida útil y, por último, permite reducir los costos de mantenimiento al minimizar las reparaciones de emergencia y el tiempo de inactividad no planificado.

Cabe destacar que ciertos signos, condiciones o indicaciones preceden el 99% de todas las fallas de máquinas, por lo que, al monitorear un activo, es posible tomar medidas preventivas antes de que estas fallas afecten gravemente el rendimiento de la organización.

A modo de resumen, el mantenimiento basado en condición es una estrategia de mantenimiento efectiva que, cuando se implementa correctamente, puede maximizar la vida útil de los componentes, reducir los costos de mantenimiento y minimizar el tiempo de inactividad no planificado. Sin embargo, su implementación requiere una organización de mantenimiento disciplinada, soporte de la gestión y un análisis robusto de datos de confiabilidad y mantenimiento financiero.

4.4 Frecuencia de Inspección en Mantenimiento

La gestión del mantenimiento debe planificar todas las actividades de mantenimiento durante la vida útil del equipo y debe ser capaz de prever y planificar las necesidades futuras de repuestos, horas/hombre y costes totales [14]. A medida que los equipos envejecen y entran en la fase de desgaste, con tasas de falla cada vez mayores, esta previsión se hace difícil y la gestión del mantenimiento se enfrenta al dilema de recurrir a inventarios elevados, una planificación excesiva y presupuestos inflados, o bien sufrir roturas de existencias, retrasos prolongados en las reparaciones y desviaciones presupuestarias, donde un modelo de frecuencia de inspección puede ayudar a corregir esta situación [15].

Las inspecciones periódicas de los equipos permiten determinar el estado real del equipo y tomar las medidas necesarias para evitar problemas. Según Ramakumar [16], una estrategia de mantenimiento basada en inspecciones puede reducir significativamente el tiempo de inactividad de los equipos que experimentan fallas aleatorias. Además, una frecuencia de inspección adecuada no solo optimiza el rendimiento del equipo sino que también prolonga su vida útil y mejora la seguridad operativa. La implementación de esta estrategia puede contribuir a una mejor planificación del mantenimiento, reducción de costos y mejora de la eficiencia general del sistema.

Por otro lado, Bloch y Geitner [17] enfatizan la importancia de implementar una estrategia de mantenimiento basada en inspecciones. Estos autores señalan que casi todas las fallas de los equipos muestran signos tempranos de falla, lo que brinda una valiosa oportunidad para intervenir antes de que ocurra una falla total. Una estrategia adecuada de inspección y mantenimiento puede identificar estos primeros signos de desgaste y tomar medidas preventivas para evitar fallas graves y costosas.

La detección temprana de signos de daño permite tomar medidas oportunas, lo que no sólo evita fallas sino que también prolonga la vida útil del equipo y mejora su rendimiento general. Sin embargo, es importante darse cuenta de que cada inspección genera costos adicionales. Estos costos pueden incluir la mano de obra necesaria para realizar la inspección, el equipo y las herramientas necesarios y el tiempo de inactividad del equipo durante la inspección. Por este motivo, el objetivo principal debe ser desarrollar una estrategia de inspección adecuada, es decir, minimizando el costo total. Este costo total incluye tanto los costos directos de realizar la inspección como los costos indirectos asociados al problema que se quiere evitar, es decir, la inminente falla.

Una estrategia de inspecciones bien diseñada debe equilibrar la frecuencia de las inspecciones y los costos asociados para minimizar el impacto económico y operativo en la organización. De esta manera, la estrategia de mantenimiento de inspección no solo minimiza los costos totales sino que también maximiza la confiabilidad y disponibilidad del equipo. Esto conduce a operaciones más eficientes, seguras y rentables, beneficiando a toda la organización [15].

4.5 Uso de la Distribución Weibull en Mantenimiento

La distribución Weibull es ampliamente utilizada en el ámbito del mantenimiento y la confiabilidad debido a su flexibilidad para modelar distintos tipos de tasas de falla a lo largo del tiempo. Al contar con un parámetro de forma ajustable, la distribución Weibull permite representar tanto sistemas cuyo riesgo de falla aumenta con el tiempo, como aquellos que tienen una tasa de falla constante o decreciente [18].

4.5.1. Función de Densidad de Probabilidad (PDF)

La función de densidad de probabilidad (PDF) de la distribución Weibull es una herramienta fundamental en el análisis de confiabilidad y mantenimiento, ya que permite modelar distintos patrones de fallas a lo largo del ciclo de vida de un sistema o componente. La distribución Weibull es altamente flexible, y su forma puede variar en función de sus parámetros, lo que la hace especialmente útil para describir diferentes tipos de comportamientos de fallas. Los dos parámetros principales de la distribución Weibull corresponden al parámetro de forma β y al parámetro de escala α , los cuales permiten interpretar las características del proceso de fallas y ajustar la estrategia de mantenimiento [18, 19].

La función de densidad de probabilidad (PDF) de la distribución Weibull está dada por la siguiente expresión:

$$f(t) = \frac{\beta}{\alpha} \left(\frac{t}{\alpha} \right)^{\beta-1} e^{-(t/\alpha)^\beta}, \quad (4.1)$$

donde t es el tiempo, β es el parámetro de forma, y α es el parámetro de escala.

4.5.2. Función de Confiabilidad

De acuerdo con Smith [20] la función de confiabilidad $R(t)$ es fundamental en el análisis de sistemas y componentes, ya que describe la probabilidad de que un equipo opere sin fallas hasta un tiempo específico t . En el caso de la distribución Weibull, esta función se expresa como:

$$R(t) = e^{-(t/\alpha)^\beta}, \quad (4.2)$$

donde α es el parámetro de escala y β es el parámetro de forma. El parámetro α define el tiempo característico o vida útil promedio. El parámetro β , por su parte, determina el comportamiento del sistema a lo largo del tiempo, reflejando diferentes patrones según su valor:

- Si $\beta < 1$, la tasa de falla disminuye con el tiempo. Este comportamiento, conocido como fallas tempranas, es típico de componentes que enfrentan defectos iniciales en la fabricación o instalación, pero que se estabilizan después de superar esta fase crítica.

- Si $\beta = 1$, la tasa de falla permanece constante a lo largo del tiempo. Este escenario se conoce como fallas aleatorias y se observa comúnmente en sistemas electrónicos o en equipos con redundancias bien diseñadas. Aquí, la confiabilidad $R(t)$ decrece de forma exponencial, indicando que la probabilidad de que el sistema falle es independiente de su edad o tiempo de operación.
- Si $\beta > 1$, la tasa de falla incrementa con el tiempo, lo que representa el fenómeno de desgaste. Este comportamiento es típico en componentes sometidos a envejecimiento o acumulación de desgaste. En este caso, la confiabilidad $R(t)$ decrece más rápidamente a medida que el tiempo avanza, reflejando un aumento significativo en la probabilidad de falla a medida que el componente envejece.

La función de confiabilidad es particularmente útil en el ámbito del mantenimiento, ya que permite predecir la probabilidad de supervivencia de un componente en un horizonte temporal específico. Este conocimiento facilita la planificación de actividades como inspecciones, reemplazos programados o intervenciones preventivas antes de alcanzar niveles críticos de degradación.

En el contexto de estrategias de mantenimiento preventivo, la evaluación de $R(t)$ permite comparar la confiabilidad de diferentes componentes o sistemas, identificando aquellos que requieren mayor atención o presentan mayor riesgo. Asimismo, ayuda a fundamentar decisiones para implementar políticas que maximicen la disponibilidad y reduzcan costos asociados al tiempo de inactividad no planificado.

4.5.3. Tasa de Falla (Hazard Rate)

La tasa de falla instantánea o función de riesgo $\lambda(t)$ es una herramienta fundamental en la gestión del mantenimiento, ya que proporciona información sobre la probabilidad de que un componente falle en un instante específico t , dado que ha funcionado sin fallas hasta ese momento. En el contexto de la distribución Weibull, la tasa de falla se define como:

$$\lambda(t) = \frac{f(t)}{R(t)} = \frac{\beta}{\alpha} \left(\frac{t}{\alpha} \right)^{\beta-1}, \quad (4.3)$$

donde $f(t)$ es la función de densidad de probabilidad y $R(t)$ es la función de confiabilidad del componente. El parámetro α actúa como un factor de escala, definiendo el horizonte temporal asociado a la vida útil del componente.

La tasa de falla permite identificar en qué momento del ciclo de vida de un componente las fallas son más probables, lo que la convierte en una herramienta crucial para el diseño de estrategias de mantenimiento. Por ejemplo, en sistemas industriales, puede usarse para optimizar la planificación de inspecciones y determinar los intervalos ideales para realizar tareas de mantenimiento preventivo o predictivo. Esto resulta en una mejora significativa en la confiabilidad de los sistemas y una reducción en los costos asociados al mantenimiento

correctivo o a las fallas no planificadas [18, 19, 20].

4.6 Simulación de MonteCarlo Aplicada en Mantenimiento

De acuerdo con Mooney [21], la simulación de MonteCarlo es una técnica estadística ampliamente utilizada para modelar y analizar sistemas que presentan incertidumbre. Este método se basa en la generación de números aleatorios y en la repetición de experimentos computacionales, lo que permite evaluar cómo las variables inciertas impactan los resultados de un modelo.

En esencia, el enfoque de MonteCarlo permite aproximar soluciones a problemas complejos al realizar múltiples iteraciones que simulan diferentes escenarios posibles. Estas simulaciones utilizan distribuciones de probabilidad para modelar fenómenos aleatorios, como tiempos entre fallas, costos o duraciones de procesos. Por su versatilidad, esta metodología se emplea en campos como la ingeniería, las finanzas y la logística, destacándose particularmente en la gestión de activos industriales.

Según lo planteado por dicho autor en su libro *Monte Carlo Simulation*, un modelo típico de MonteCarlo sigue los siguientes pasos fundamentales:

1. Definición del modelo matemático: Se establece una representación del sistema bajo estudio, incorporando variables clave y relaciones entre ellas.
2. Asignación de distribuciones de probabilidad: Se asocia una distribución adecuada a cada variable aleatoria, basándose en datos históricos o estimaciones teóricas.
3. Generación de escenarios: Se utilizan generadores de números pseudoaleatorios para simular múltiples posibles estados del sistema.
4. Cálculo de métricas clave: Se evalúan indicadores de desempeño, como confiabilidad, disponibilidad o costos esperados.
5. Análisis estadístico de resultados: Los resultados obtenidos en cada iteración se sintetizan para obtener distribuciones y estadísticas que apoyen la toma de decisiones.

4.6.1. Muestreo de Números Aleatorios

De acuerdo con el libro *The Monte Carlo Simulation Method for System Reliability and Risk Analysis* de Enrico Zio [22], el muestreo de números aleatorios es una técnica fundamental en la simulación MonteCarlo, especialmente cuando se requiere modelar fenómenos inciertos o probabilísticos en sistemas complejos. Este método permite generar valores que obedecen distribuciones específicas a partir de distribuciones básicas, como por ejemplo la distribución uniforme.

Para comprender este método se debe considerar una variable aleatoria X cuya función de distribución acumulada (cdf, por sus siglas en inglés) está definida como:

$$P(X \leq x) = F_X(x); \quad F_X(-\infty) = 0; \quad F_X(\infty) = 1.$$

En este contexto, si la variable aleatoria X sigue una cdf específica, se denota como $X \sim F_X(x)$. La cdf $F_X(x)$ es una función no decreciente que, para mayor aplicabilidad, se considera continua y diferenciable. Su función de densidad de probabilidad (pdf) asociada se define como:

$$f_X(x) = \frac{dF_X(x)}{dx}; \quad f_X(x) \geq 0; \quad \int_{-\infty}^{\infty} f_X(x) dx = 1.$$

El objetivo del muestreo es generar valores que sigan la distribución definida por $F_X(x)$. Para ello, una secuencia de $N \gg 1$ muestras, representada como $\{X\} \equiv \{x_1, x_2, \dots, x_N\}$, debe cumplir con la condición de que el número n de muestras dentro de un intervalo $\Delta x \ll X_{\max} - X_{\min}$ se relacione con la pdf como:

$$\frac{n}{N} \simeq \int_{\Delta x} f_X(x) dx.$$

Esto significa que el histograma de las muestras debe aproximarse a $f_X(x)$. Además, las muestras deben ser no correlacionadas, y si la secuencia es periódica, su período debe ser lo suficientemente largo para evitar repeticiones tempranas.

Entre todas las distribuciones, la distribución uniforme $U[0, 1)$, que genera valores en el intervalo $[0, 1)$, es fundamental. Mediante el uso de números aleatorios generados desde esta distribución, es posible transformar estos valores para ajustarse a cualquier otra distribución deseada.

Este proceso es crucial en simulaciones de MonteCarlo, ya que las distribuciones uniformes proporcionan la base para construir muestras representativas de distribuciones más complejas. Por ejemplo, el método de la transformación inversa utiliza la relación $x = F_X^{-1}(u)$, donde $u \sim U[0, 1)$, para generar muestras x de una distribución específica. Este enfoque es ampliamente utilizado debido a su simplicidad y versatilidad en la práctica computacional.

4.6.2. Aplicación en Mantenimiento

En el ámbito del mantenimiento industrial, la simulación de MonteCarlo es una herramienta clave para abordar la incertidumbre inherente a los sistemas técnicos y operativos. Este enfoque permite integrar datos relacionados con la confiabilidad de los equipos, los costos operativos y los tiempos de reparación para optimizar estrategias de mantenimiento adaptadas a diferentes escenarios.

Una de las aplicaciones más destacadas de esta metodología es la planificación de políticas de mantenimiento. Gracias a su capacidad para modelar escenarios estocásticos, la simulación permite evaluar la efectividad de diversas estrategias, como el mantenimiento preventivo, predictivo o correctivo. Este análisis facilita la selección de la política que maximice la

disponibilidad de los equipos al menor costo posible, minimizando los tiempos de inactividad y el impacto en la producción [22].

Otro uso relevante es el análisis de inventarios. La simulación de MonteCarlo ayuda a prever las necesidades de repuestos y materiales considerando la variabilidad en las tasas de falla y los tiempos de reparación. Esto reduce tanto el riesgo de desabastecimiento como los costos asociados a un exceso de inventario, logrando un equilibrio adecuado entre disponibilidad y costos operativos [23].

Además, la simulación permite evaluar el ciclo de vida de los equipos, proporcionando información detallada para tomar decisiones sobre reparación, reemplazo o modernización. Esto resulta especialmente útil para prolongar la vida útil de activos críticos sin comprometer la seguridad ni la eficiencia operativa [24].

Finalmente, la simulación de MonteCarlo facilita la predicción de tiempos de inactividad, modelando escenarios de fallas y reparaciones. Esto permite estimar con mayor precisión tanto las paradas planificadas como las no planificadas, lo que se traduce en una gestión más eficiente de los recursos y una mayor estabilidad operativa [25].

En conclusión, la simulación de MonteCarlo no solo mejora las capacidades de predicción en mantenimiento, sino que también proporciona herramientas para optimizar la toma de decisiones estratégicas en la gestión de activos industriales.

4.7 Evaluación de Desempeño y Métricas en Mantenimiento

El mantenimiento desempeña un papel crucial y tiene un impacto significativo en los resultados de las empresas industriales. Por lo tanto, es esencial gestionar el mantenimiento, observar, comprender y mejorar las acciones mediante la adopción de indicadores de rendimiento bien elegidos en función de las necesidades de la empresa [26]. Estos indicadores se conocen como KPI de mantenimiento o indicadores clave de rendimiento, que permiten recopilar conocimientos y explorar los mejores medios para alcanzar los objetivos de la organización. Los KPI de mantenimiento son fundamentales para realizar un seguimiento de la función, supervisar el rendimiento y garantizar el cumplimiento de las expectativas empresariales [27]. Además, los KPI impulsan el crecimiento de la confiabilidad al tiempo que orientan las decisiones para mejorar la eficiencia y el rendimiento del mantenimiento.

4.7.1. Indicadores Clave de Desempeño en Mantenimiento

Según Parmenter [28], los indicadores clave de rendimiento (KPI) son medidas enfocadas en los aspectos más críticos del desempeño organizativo, fundamentales para garantizar el éxito presente y futuro. En el contexto del mantenimiento, los KPI cumplen con varios objetivos. Por un lado, proporcionan información sobre los resultados obtenidos respecto a los objetivos planteados, evaluando así el grado de adecuación de las acciones realizadas en relación con la

estrategia organizativa. También ofrecen datos esenciales, relevantes y oportunos que son clave para la toma de decisiones por parte de los directivos.

Estos indicadores deben ser comprensibles, medibles y fácilmente representables, permitiendo su utilización por toda la organización, incluyendo a los operarios de las áreas de producción. Además, es crucial que los KPI abarquen todas las actividades de mantenimiento, garantizando una alineación con la estrategia global de la empresa. Sin embargo, deben ser limitados en número para que puedan emplearse eficazmente como herramientas de apoyo en la gestión y toma de decisiones.

Los KPI de mantenimiento permiten supervisar, comparar y mejorar las intervenciones de mantenimiento de los equipos se clasifican generalmente en tres categorías:

1. KPI de costos de mantenimiento.
2. KPI de actividades de mantenimiento de equipos.
3. KPI de rendimiento del mantenimiento.

Cada una de estas categorías cubre un aspecto del rendimiento del equipo o de un sistema de mantenimiento.

4.7.1.1. KPIs de Costo de Mantenimiento

Según lo descrito por Berrabah [26], los KPI vinculados al costo de mantenimiento son:

- **Costo de intervención:** Incluye los gastos relacionados con el mantenimiento preventivo y correctivo. No incluye los costos de inversión ni los relacionados directamente con la producción. El coste de intervención puede descomponerse en mano de obra interna o externa, stock de piezas de recambio o compradas para una intervención, material necesario para la intervención, entre otros.
- **Coste de Falla:** Estos costos corresponden a las pérdidas en el margen de explotación debidas a un problema de mantenimiento que ha reducido el ritmo de producción de productos en buen estado. La pérdida de este margen puede incluir un aumento de los costes de explotación o una pérdida de negocio.
- **Costo de almacenamiento:** El costo de almacenamiento representa los costes incurridos en financiación y manipulación del inventario necesario de piezas de repuesto y consumo para la función de mantenimiento.
- **Costo de inversión:** Al diseñar la planta, la decisión correcta es la que disminuye el coste global de mantenimiento del activo durante toda su vida útil. Esto implica que se compran equipos más significativos que las necesidades exactas de productividad con las inversiones iniciales.

4.7.1.2. KPIs de Actividades de Mantenimiento

En cuanto a los KPIs relacionados con las actividades de mantenimiento, Berrabah [26] describe los siguientes:

- **Disponibilidad de equipos:** La disponibilidad es la probabilidad de funcionamiento del equipo en el momento t . De ella dependen: el número de fallas (confiabilidad), la velocidad de reparación (mantenibilidad), los procedimientos definidos (organización del mantenimiento) y la calidad de los medios (logística).
- **Confiabilidad de los Equipos:** El principal KPI de esta categoría es el MTBF (Mean Time Between Failure) que corresponde a la media de funcionamiento correcto; este indicador es la probabilidad de que un equipo realice una operación requerida en unas condiciones dadas y en un periodo bien definido. Otros indicadores de confiabilidad son: MTTF (Mean Time To Failure), que indica el tiempo medio de funcionamiento del sistema antes del primer fallo, y el MUT (Mean Up Time) que es el tiempo medio de funcionamiento después de la reparación.

4.7.1.3. KPIs de Rendimiento del Mantenimiento

En esta categoría, se describen los siguientes KPIs, de acuerdo con Gonzalez [29]:

- **La tasa de planificación:** Corresponde a la relación entre las horas previstas para las operaciones planificadas y el número total de horas disponibles.
- **The Completion rate (tasa de realización):** Corresponde a la relación entre las tareas de mantenimiento programadas finalizadas a tiempo y el número total de tareas. Puede utilizarse para evaluar la eficacia de la ejecución del mantenimiento o la precisión de la planificación del mantenimiento.

4.8 Evaluación del Riesgo en Mantenimiento

La evaluación del riesgo en mantenimiento es una herramienta fundamental para identificar, analizar y gestionar los factores de incertidumbre que afectan el desempeño de los sistemas técnicos y organizativos. Esta disciplina combina conceptos de probabilidad, estadística y teoría de decisiones para garantizar que los recursos destinados al mantenimiento sean empleados de manera eficiente, minimizando las fallas críticas y los costos asociados [30, 31].

El riesgo en mantenimiento puede ser entendido como una combinación de la probabilidad de ocurrencia de un evento adverso, como una falla, y las consecuencias de dicho evento en términos de tiempo, costos o seguridad [32]. Las principales metodologías para la evaluación del riesgo incluyen el uso de indicadores estadísticos, simulaciones y análisis de escenarios [33].

4.8.1. Conditional Value at Risk (CVaR)

El *Value-at-Risk* (VaR) y el *Conditional Value-at-Risk* (CVaR) son medidas ampliamente utilizadas en el análisis de incertidumbre y evaluación de riesgos. En el contexto de confiabilidad y mantenimiento, estas medidas permiten evaluar el impacto de eventos inesperados en sistemas técnicos o procesos industriales, facilitando la toma de decisiones basada en el riesgo.

Rockafellar y Uryasev [34, 35] mencionan que el *Value-at-Risk* es una medida que indica la mayor pérdida esperada de un sistema bajo un nivel de confianza específico α . Formalmente, para una variable aleatoria X (que en este contexto puede representar la pérdida de funcionalidad o el costo de un fallo), con función de distribución acumulativa $F_X(z) = P\{X \leq z\}$, el VaR se define como:

$$\text{VaR}_\alpha(X) = \min\{z \mid F_X(z) \geq \alpha\}.$$

En términos prácticos, $\text{VaR}_\alpha(X)$ representa el valor que no será excedido por X con una probabilidad de al menos α . Por ejemplo, si $\alpha = 0.95$, el VaR corresponde al nivel de pérdida que será excedido solo en un 5% de los casos.

Para distribuciones normales, donde $X \sim N(\mu, \sigma^2)$, el VaR se puede calcular de manera explícita como:

$$\text{VaR}_\alpha(X) = \mu + k(\alpha)\sigma,$$

donde $k(\alpha) = \sqrt{2} \text{erf}^{-1}(2\alpha - 1)$ y $\text{erf}(z)$ es la función de error definida como:

$$\text{erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt.$$

Por otro lado, estos autores indican que el *Conditional Value-at-Risk*, también conocido como *Expected Shortfall*, es una extensión del VaR que mide la expectativa condicional de X dado que X excede el valor de VaR. En otras palabras, el CVaR estima el valor promedio de las pérdidas más extremas que superan el VaR. Esto lo hace particularmente útil en el análisis de sistemas de confiabilidad, donde es crítico considerar el impacto de fallos severos [36].

Para una función de distribución acumulativa continua, el CVaR se define como:

$$\text{CVaR}_\alpha(X) = \mathbb{E}[X \mid X \geq \text{VaR}_\alpha(X)].$$

En el caso general, el CVaR también puede expresarse como una integral:

$$\text{CVaR}_\alpha(X) = \frac{1}{1 - \alpha} \int_{\text{VaR}_\alpha(X)}^{\infty} z f_X(z) dz,$$

donde $f_X(z)$ es la función de densidad de X .

En situaciones prácticas, el CVaR es preferido sobre el VaR porque, además de ser más sensible

a los eventos extremos, es una función continua y convexa respecto al nivel de confianza α , lo que facilita su optimización en aplicaciones como el diseño de planes de mantenimiento preventivo o la asignación de recursos para mitigar riesgos en sistemas críticos.

El uso del CVaR en mantenimiento permite una mejor planificación de políticas preventivas y correctivas, especialmente en entornos de alta incertidumbre y riesgo, como plantas industriales donde la falla de un equipo puede generar costos adicionales significativos, tanto en términos de tiempo de inactividad como en costos de reparación. Esta métrica también es esencial para evaluar la efectividad de estrategias de mantenimiento predictivo, donde el objetivo es prevenir fallas extremas que podrían tener consecuencias graves.

4.8.2. Análisis de Dominancia

El análisis de dominancia es una herramienta utilizada en la teoría de decisiones y en la evaluación de riesgos que busca comparar diferentes alternativas para determinar cuál de ellas es más *dominante* o eficiente en relación con ciertos criterios. Este enfoque es particularmente útil cuando se enfrentan decisiones con múltiples objetivos y se necesita identificar la mejor opción según un conjunto de parámetros predefinidos.

En el contexto del mantenimiento, el análisis de dominancia se puede aplicar para evaluar y seleccionar las políticas de mantenimiento más efectivas en función de distintos criterios, como el costo, la disponibilidad, el tiempo de inactividad, entre otros.

Para ilustrar el concepto de dominancia en un contexto de decisiones multi-criterio, es necesario considerar dos alternativas A y B , evaluadas a través de n criterios C_1, C_2, \dots, C_n . Se dice que la alternativa A domina a B si y solo si:

$$C_i(A) \geq C_i(B) \quad \text{para todo } i \in \{1, 2, \dots, n\}$$

y

$$C_i(A) > C_i(B) \quad \text{para al menos un } i.$$

En otras palabras, una alternativa A es dominante si no es peor que B en ningún criterio y, además, es mejor que B en al menos un criterio. Si esto ocurre, se puede afirmar que A es preferible a B .

En un contexto estocástico, el análisis de dominancia toma un enfoque más avanzado que se denomina *Dominancia estocástica*. Este se utiliza cuando las alternativas están representadas por distribuciones probabilísticas en lugar de valores deterministas y, en estos casos, una alternativa A domina estocásticamente a B si, para cualquier función creciente $f(x)$, la esperanza de $f(A)$ es mayor que la esperanza de $f(B)$ [37]. Matemáticamente, esto se expresa como:

$$\mathbb{E}[f(A)] \geq \mathbb{E}[f(B)] \quad \forall f(x) \text{ creciente.}$$

Esto implica que, a lo largo de toda la distribución, A tiene mejores resultados esperados que B , y es útil para comparar alternativas que involucran incertidumbre o variabilidad en los resultados.

Este enfoque es comúnmente utilizado en campos como las finanzas, como se observa en el artículo de Chang et al. [37], pero también se puede aplicar en el contexto del mantenimiento, puesto que, escenarios complejos de mantenimiento donde las fallas de los equipos son aleatorias y las distribuciones de costos pueden ser inciertas, la dominancia estocástica ofrece una herramienta eficaz para comparar distintas políticas de mantenimiento. Por ejemplo, si se conocen las distribuciones de costos asociadas a las estrategias A y B , es posible determinar cuál de estas alternativas presenta el menor costo esperado a lo largo del tiempo, considerando tanto los costos directos como los derivados de los tiempos de inactividad o los riesgos asociados a las fallas.

4.8.3. Análisis de Sensibilidad

Según lo planteado por Saltelli [38] el análisis de sensibilidad es una técnica fundamental para evaluar cómo las variaciones en las variables clave de un sistema afectan los resultados esperados del modelo de mantenimiento. Este enfoque permite identificar los factores críticos que contribuyen de manera significativa al riesgo, tales como las tasas de falla, tiempos de reparación o costos asociados. Dicho análisis es esencial para desarrollar estrategias de mantenimiento más robustas y optimizar la asignación de recursos.

Matemáticamente, el análisis de sensibilidad se representa mediante derivadas parciales que cuantifican la relación entre una variable independiente x_i y el indicador de riesgo R :

$$S_i = \frac{\partial R}{\partial x_i}, \quad (4.4)$$

donde S_i es el coeficiente de sensibilidad de la variable x_i . Un valor elevado de S_i indica que pequeñas variaciones en x_i tendrán un impacto significativo en el riesgo.

Además del análisis basado en derivadas parciales, es común utilizar un enfoque de sensibilidad global que evalúa el impacto conjunto de múltiples variables de entrada sobre el modelo. Para este caso, se utiliza la varianza como medida de incertidumbre y se descompone mediante índices de Sobol, que cuantifican el aporte individual y combinado de cada variable al resultado:

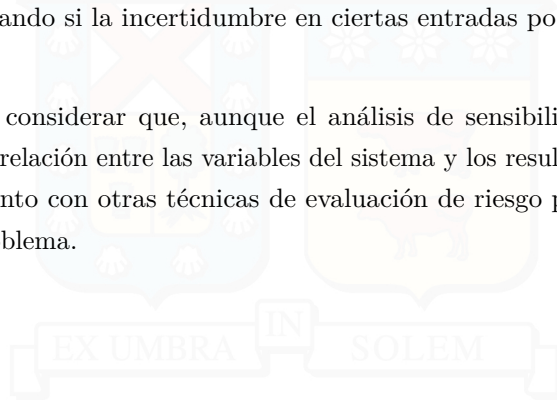
$$S_i^{\text{Sobol}} = \frac{\text{Var}_{x_i}(\mathbb{E}[R | x_i])}{\text{Var}(R)}, \quad (4.5)$$

$$S_{T_i} = \frac{\text{Var}(R) - \text{Var}_{\sim x_i}(\mathbb{E}[R | x_{\sim i}])}{\text{Var}(R)}, \quad (4.6)$$

donde S_i^{Sobol} representa el índice de primer orden, y S_{T_i} el índice de sensibilidad total, que captura los efectos de interacción entre variables.

En el contexto del mantenimiento, estas técnicas permiten determinar qué parámetros tienen mayor impacto en los indicadores que se están analizando, como puede ser el caso de los costos de mantenimiento. Además, este análisis también resulta útil para validar modelos de mantenimiento, identificando si la incertidumbre en ciertas entradas podría invalidar las predicciones.

Finalmente, es importante considerar que, aunque el análisis de sensibilidad proporciona información valiosa sobre la relación entre las variables del sistema y los resultados del modelo, debe interpretarse en conjunto con otras técnicas de evaluación de riesgo para obtener una visión más completa del problema.



5 | Estado del Arte

La determinación de la frecuencia óptima de inspección en mantenimiento ha significado un tema de gran interés en la literatura, siendo abordado desde diferentes perspectivas metodológicas y aplicativas a lo largo de las décadas. Dado esto, la presente sección revisa investigaciones previas relacionadas con el tema principal de este estudio, con la finalidad de contextualizar e indicar el estado actual de esta línea de investigación.

Por la década de 1970, Yang y Trap [39] abordaron la optimización de la frecuencia de inspección en estructuras de aeronaves mediante un modelo basado en el análisis de confiabilidad. Este enfoque se centró en minimizar los costos esperados asociados a inspecciones y fallas, formulando una función de costo total C^* que integraba costos de inspección, mantenimiento y las consecuencias de las fallas inesperadas. Un aspecto clave fue la incorporación de la relación entre los costos de inspección y los costos de falla $\gamma = \frac{C_i}{C_f}$, que permitió establecer una frecuencia óptima N^* de inspección, balanceando confiabilidad y costos. Además de lo anterior, el artículo destacó la necesidad de ajustar los intervalos de inspección según la etapa de vida útil en que se encuentre el equipo o sistema en estudio.

Posteriormente, Alfares [40] extendió estas ideas acerca de la frecuencia de inspección al ámbito de las plantas petroquímicas, desarrollando un modelo de simulación para determinar la frecuencia óptima de inspección de válvulas de alivio. Este enfoque incluyó no solo costos directos de inspección y mantenimiento, sino también riesgos asociados a fallos catastróficos. Utilizando el software SLAMSYSTEM, el modelo consideró características específicas de los equipos, como presión, temperatura y antigüedad, y empleó distribuciones probabilísticas para modelar el tiempo entre fallos. La política propuesta permitió reducir significativamente los costos totales de mantenimiento en un 49%, sin comprometer la seguridad operativa, demostrando la utilidad de la simulación para validar estrategias antes de su implementación en sistemas reales.

En el año 2004, Mathew [15] avanzó aún más al integrar dinámicamente la evolución de las tasas de fallos a lo largo de la vida útil de los equipos. Su modelo utilizó la distribución Weibull para caracterizar la tasa de fallos en tres etapas principales: tasa decreciente (DFR), tasa constante (CFR) y tasa creciente (IFR). La frecuencia de inspección $n(t)$ fue definida como una función del tiempo, ajustándose a las condiciones específicas de cada etapa. Este enfoque no solo optimizó los costos de mantenimiento, sino que también proporcionó herramientas predictivas para planificar reemplazos y gestionar recursos de manera más efectiva. El trabajo destacó cómo las tasas de fallos variables pueden influir en las decisiones de mantenimiento, aportando una perspectiva más integral al problema.

Más recientemente, Babishin y Taghipour [41] introdujeron un enfoque para sistemas multi-componente que incorpora tanto inspecciones periódicas como oportunistas. El modelo clasifica

los componentes en "duros" "blandos", optimizando la frecuencia de inspección τ^* mediante simulaciones para minimizar costos de inspección, reparación y tiempo de inactividad. Este trabajo enfatizó cómo las inspecciones oportunistas, generadas tras fallos en componentes duros, pueden complementar las periódicas, mejorando la confiabilidad global del sistema. La dependencia estocástica entre componentes añade un nivel de complejidad que se aborda eficazmente mediante simulaciones, lo que representa un paso adelante en la optimización de políticas para sistemas complejos.

Un año más tarde, Alaswad [1] abordó el problema desde la perspectiva del mantenimiento basado en condición (CBM), evaluando diferentes enfoques de inspección: monitoreo continuo, inspecciones periódicas y no periódicas. Este estudio destacó las ventajas y desventajas de cada enfoque, enfatizando que las inspecciones no periódicas ofrecen mayor flexibilidad y ahorro de costos al ajustar dinámicamente los intervalos según el estado del sistema. Además, se introdujo el enfoque multiobjetivo como una herramienta para balancear criterios como costos, confiabilidad y disponibilidad.

Tiempo después, Shafiee [42] exploró métodos para optimizar la planificación de inspecciones en sistemas de energía eólica, con especial atención a parques offshore. Este trabajo integró enfoques basados en confiabilidad, como procesos de Weibull y modelos de tiempo de retraso, para ajustar los intervalos de inspección según la degradación detectada. Además, se aplicaron simulaciones de Monte Carlo y análisis de riesgos para abordar factores críticos, como condiciones ambientales adversas y dependencias entre componentes. Este enfoque permitió balancear costos de inspección con la disponibilidad del sistema, destacando el uso de tecnologías emergentes, como monitoreo continuo e inteligencia artificial, para ajustar dinámicamente las estrategias de inspección.

Luego, Assis y Marques [43] propusieron una metodología dinámica para calcular intervalos de inspección en mantenimiento preventivo basado en condiciones. Este enfoque utiliza la distribución Weibull para modelar fallos y considera la curva P-F y ventanas de tiempo seguras/inseguras para optimizar la planificación. El modelo ajusta los intervalos tras cada inspección, basándose en resultados reales, con el objetivo de minimizar costos totales esperados mientras se mantiene la confiabilidad en niveles aceptables. Este trabajo resalta la importancia de la adaptabilidad y la eficiencia en sistemas críticos, como aquellos utilizados en manufactura avanzada y energía.

Ya en los últimos años, trabajos como el de Nasrfard et al. [5] desarrollaron un modelo probabilístico para optimizar tasas de inspección en sistemas multicomponente bajo mantenimiento preventivo. Utilizando cadenas semi-Markov y simulaciones de Monte Carlo, el enfoque consideró correlaciones entre costos, duraciones de mantenimiento y estados de los componentes. Este modelo incorpora incertidumbre y dependencias entre componentes, permitiendo optimizar políticas de inspección para minimizar costos y maximizar la disponibilidad del sistema. La metodología es particularmente útil en sistemas complejos y destacó cómo las correlaciones no consideradas pueden distorsionar significativamente los resultados de planificación.

Otro trabajo actual corresponde al de Zhang et al. [44], que introducen un modelo jerárquico que

combina inspecciones parciales y completas para sistemas con degradación estocástica continua. Este modelo optimiza tanto los intervalos de inspección como las políticas de mantenimiento preventivo y correctivo, utilizando procesos Gamma para modelar la degradación del sistema. Las inspecciones parciales ($\Delta\tau$) son evaluaciones rápidas que identifican problemas potenciales, mientras que las inspecciones completas (τ) proporcionan análisis detallados. Un coeficiente óptimo ($k = \frac{\tau}{\Delta\tau}$) equilibra costos operativos e interrupciones, minimizando el costo promedio por unidad de tiempo. Este enfoque es especialmente relevante para sistemas industriales críticos, como válvulas de seguridad y compresores.

Finalmente, Liu et al. [45] propusieron una política híbrida de mantenimiento preventivo basado en condiciones (CBM-HPM) aplicada a equipos arrendados. El modelo integra inspecciones periódicas con decisiones dinámicas de mantenimiento preventivo y correctivo, buscando minimizar costos durante el período de arrendamiento. Utilizando un proceso Gamma para modelar el deterioro acumulativo, optimizan el período de inspección (T^*) y definen umbrales para mantenimiento imperfecto y reemplazo preventivo. Este enfoque es especialmente relevante en contratos de arrendamiento, donde los costos del arrendador y las condiciones de garantía deben equilibrarse. Los resultados muestran reducciones de costos del 10-15 % comparado con políticas tradicionales.

En conjunto, estas investigaciones han permitido avances significativos en la comprensión y optimización de la frecuencia de inspección, evolucionando desde modelos basados en confiabilidad y costos hacia enfoques dinámicos que integran características específicas del equipo y la vida útil, no obstante, persisten algunos desafíos importantes que merecen atención. En primer lugar, los modelos de degradación como Weibull o Gamma, aunque útiles, presentan limitaciones al asumir formas específicas de deterioro, lo que restringe su aplicación en escenarios con patrones altamente variables o no lineales [46]. Además, la literatura aborda con frecuencia los componentes de manera aislada, lo que subestima las dependencias complejas entre ellos y sus efectos acumulativos en sistemas multicomponente. También es notable que, aunque algunas investigaciones han explorado el monitoreo continuo, la integración total de datos en tiempo real sigue siendo un área emergente, especialmente en contextos donde las capacidades tecnológicas son limitadas.

Estos aspectos no resueltos subrayan la necesidad de futuras investigaciones que desarrollen modelos más flexibles y robustos. Estos modelos deben ser capaces de integrar dependencias complejas entre componentes, abordar múltiples objetivos de manera simultánea y aprovechar tecnologías emergentes, como la inteligencia artificial y el aprendizaje automático. Dichas innovaciones tienen el potencial de revolucionar las estrategias de inspección y mantenimiento, logrando un equilibrio óptimo entre costos, confiabilidad y sostenibilidad. En este contexto, el presente trabajo propone una metodología y un modelo para determinar la frecuencia óptima de inspección, diseñados con un enfoque singular que prioriza la adaptabilidad en su aplicación práctica. Además, este modelo pretende servir como un punto de partida en esta línea de investigación, abriendo camino hacia enfoques más amplios, como metodologías sistémicas o de optimización multiobjetivo, que contribuyan al avance integral de esta área de estudio.

6 | Metodología

La metodología de este proyecto se estructura en cinco etapas fundamentales, cada una vital para alcanzar los objetivos de la investigación. A continuación, se detallan estas etapas clave del proceso:

1. **Revisión Bibliográfica:**

- Realizar una revisión exhaustiva de la literatura científica y técnica relacionada con modelos de optimización del tiempo entre inspecciones y estrategias de mantenimiento basadas en inspecciones en el ámbito industrial.
- Identificar los principales enfoques, metodologías y herramientas utilizadas en investigaciones previas sobre este tema.
- Analizar casos de estudio y aplicaciones prácticas de modelos similares en la industria para comprender sus ventajas, limitaciones y resultados obtenidos.

2. **Formulación del Modelo Propuesto:**

- Definir los parámetros del modelo de simulación.
- Incorporar factores estocásticos y probabilísticos para reflejar la incertidumbre inherente a los procesos de fallo y reparación de los equipos.
- Seleccionar las variables críticas y establecer las relaciones entre ellas para desarrollar un modelo que represente adecuadamente el problema del tiempo entre inspecciones.

3. **Aplicación del Modelo con Parámetros Representativos:**

- Definir valores para los parámetros del modelo, basados en información realista de entornos industriales.
- Implementar el modelo de simulación utilizando los parámetros definidos y ejecutar las simulaciones necesarias para evaluar el desempeño del modelo.

4. **Evaluación de Resultados:**

- Analizar los resultados obtenidos en términos de costos y disponibilidad operativa para determinar la viabilidad y eficacia del modelo propuesto.
- Sensibilizar los resultados para observar el comportamiento de estos y el impacto de los diferentes parámetros en el costo operativo y la disponibilidad.

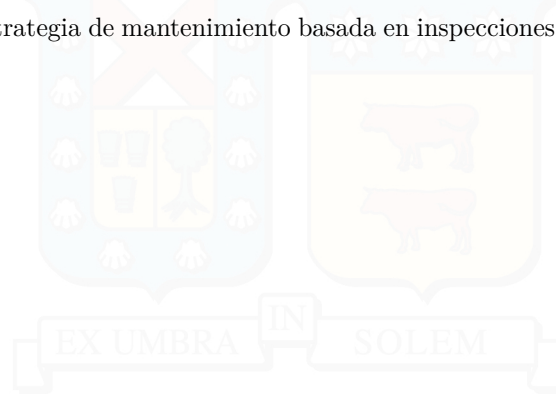
5. **Propuestas y Recomendaciones:**

- Proponer recomendaciones y mejoras para la implementación práctica del modelo en entornos industriales, considerando aspectos como la criticidad de los equipos, la

disponibilidad de recursos y la planificación a largo plazo.

- Identificar áreas de investigación futura y posibles extensiones del modelo para abordar aspectos no considerados en este estudio inicial.

Esta metodología integral combina análisis teórico y desarrollo técnico para garantizar la robustez y aplicabilidad del modelo propuesto en el contexto de la optimización del tiempo entre inspecciones en una estrategia de mantenimiento basada en inspecciones periódicas.



7 | Formulación del Modelo

El modelo propuesto para abordar la problemática se basa en una simulación estocástica que integra las actividades de mantenimiento preventivo y correctivo, así como la ocurrencia de fallas y la realización de inspecciones. Esta integración se lleva a cabo mediante la definición de parámetros aleatorios que capturan la incertidumbre inherente al proceso. El objetivo principal del modelo es determinar la frecuencia óptima de inspección t_i dentro de un conjunto discreto de posibles periodicidades, minimizando el costo total esperado CT . Este costo total se compone de los costos de inspección, los costos de las intervenciones programadas y los costos asociados a las fallas.

Este modelo se basa en la premisa de que la incertidumbre en el comportamiento del equipo puede ser representada adecuadamente mediante una simulación estocástica que captura tanto los eventos aleatorios de fallas como las acciones de mantenimiento preventivo. Para ello, se emplea la distribución de Weibull, ampliamente utilizada para modelar tiempos de vida y fallas de equipos [47, 48, 49]. En este contexto, los costos asociados a las inspecciones, las intervenciones de mantenimiento y las fallas se ven influenciados por la frecuencia de las inspecciones, los tiempos de intervención, y el estado del equipo en cada instante.

El desarrollo del modelo de simulación se estructuró en dos componentes principales: la metodología general y la lógica de simulación estocástica, aspectos que se detallan en las secciones posteriores.

7.1 Metodología General

La metodología general para el desarrollo del modelo de simulación se estructura en cuatro etapas principales, como se ilustra en la Figura 7.1. Estas etapas abordan los aspectos fundamentales necesarios para garantizar la validez y aplicabilidad del modelo, y a continuación se describen en detalle:




Figura 7.1: Desarrollo del Modelo de Simulación. Fuente: Elaboración Propia.

1. **Definición de datos y parámetros:** Esta etapa establece los fundamentos del modelo a través de la identificación de variables críticas del sistema, tales como costos de mantenimiento, tiempos de inspección y tasas de falla. Además de esto, se recopila la información requerida para construir la matriz de entrada que contendrá la información asociada a los estados de deterioro del equipo, la cual asegura que se pueda modelar el comportamiento del equipo al someterlo a una política de mantenimiento preventiva basada en inspecciones periódicas. Por otro lado, los parámetros definidos son validados mediante datos históricos, literatura técnica y consultas con expertos, garantizando que representen de forma adecuada el respectivo entorno industrial.
2. **Ejecución de la simulación estocástica:** En esta etapa se implementa el modelo de simulación y se configuran las condiciones experimentales necesarias para evaluar distintos escenarios. Los parámetros definidos en la fase anterior son cargados al modelo para asegurar consistencia en los cálculos. A continuación, se configura un rango discreto de frecuencias de inspección, considerando cada una como un escenario independiente. Finalmente, se ejecutan simulaciones utilizando técnicas de Monte Carlo, lo que permite modelar la incertidumbre inherente al sistema y capturar la variabilidad de los resultados, tanto en términos de costos como de desempeño operativo.
3. **Análisis de resultados y sensibilidad:** Esta fase procesa los datos generados durante las simulaciones, permitiendo extraer información relevante sobre el desempeño del sistema. Se calculan métricas clave como el costo esperado de mantenimiento y la semi-desviación, que actúa como un indicador de riesgo. Asimismo, se realiza un análisis de sensibilidad para identificar aquellas variables que tienen un impacto significativo en los resultados, proporcionando información valiosa sobre cómo diferentes factores afectan las métricas del sistema. Además, las frecuencias de inspección evaluadas son comparadas para identificar patrones y tendencias que ayuden a seleccionar las alternativas más prometedoras.
4. **Optimización y generación de conclusiones:** En la etapa final, los resultados obtenidos se utilizan para optimizar las decisiones y formular recomendaciones prácticas. Se evalúan las alternativas en función de criterios como la minimización de costos y riesgos operativos, seleccionando la frecuencia de inspección que mejor cumpla con los objetivos del sistema. Finalmente, las conclusiones principales son documentadas, destacando las implicaciones prácticas del modelo y los beneficios potenciales de su implementación en entornos industriales. También se consideran las limitaciones del modelo y posibles líneas de investigación futura.

Este enfoque metodológico asegura una estructura clara y lógica en el desarrollo del modelo, desde la recopilación de datos hasta la optimización final, proporcionando resultados confiables y aplicables para la toma de decisiones.

7.2 Lógica de Simulación

La simulación estocástica implementada en el modelo sigue una lógica secuencial de eventos discretos, en la cual las inspecciones y fallas ocurren a lo largo del tiempo, afectando el costo total del sistema. A lo largo del horizonte de tiempo T , se definen intervalos t_i de inspección en los cuales se simulan los eventos de falla y las decisiones de mantenimiento. La distribución Weibull se utiliza para generar los STTF, que corresponden a los tiempos simulados hasta la falla y dan cuenta del comportamiento operativo del equipo. En base a estos tiempos y mediante simulación de Monte Carlo, el modelo busca capturar la dinámica de inspección y reparación y sus impactos en el costo total.

La simulación consta de cuatro fases principales, que siguen una estructura jerárquica y secuencial:

1. **Análisis de cada t_i :** Se define un conjunto de intervalos t_i , cada uno de los cuales representa un potencial tiempo entre inspecciones. Para cada t_i , se analiza su impacto en el comportamiento del sistema y el costo asociado a las inspecciones y mantenimientos preventivos y correctivos. Se evalúan diferentes valores de t_i para determinar cuál minimiza el costo total esperado del sistema.
2. **Simulación de un año de operación:** Para cada valor de t_i definido en la fase anterior, se generan n simulaciones, donde cada simulación representa un año completo de operación del sistema. Durante el año, se simulan eventos de inspección, fallas y decisiones de mantenimiento según lo requerido por el nivel de deterioro del equipo en cada instante de tiempo evaluado.
3. **Generación de eventos del año simulado:** En cada simulación anual, se generan eventos basados en los tiempos simulados hasta la falla (STTF). Estos eventos marcan los puntos clave en los que ocurren fallas o inspecciones dentro del año simulado.
4. **Análisis y cálculo de métricas:** Para cada evento generado por un STTF, se verifican las inspecciones posibles y se evalúa el estado del componente en cada una. Dependiendo del estado del equipo, se decide si es necesario realizar un mantenimiento preventivo o si se permite que el sistema continúe operando hasta la siguiente inspección o evento de falla. Además, se lleva un registro de los costos asociados a cada decisión tomada, como el costo de inspección, mantenimiento preventivo y correctivo, así como los costos de ineficiencia.

Al final de la simulación para cada t_i , se comparan los resultados obtenidos en términos de costos y se analiza cuál de los intervalos t_i minimiza el costo total esperado del sistema.

El flujo secuencial de eventos asegura que se capture la naturaleza dinámica del proceso de inspección y reparación, donde cada fase es interdependiente de la anterior. A través de este enfoque, se busca encontrar el intervalo óptimo de inspección que balancee los costos operativos y los riesgos asociados a fallas catastróficas no detectadas a tiempo. El ciclo se repite para diferentes valores de t_i , lo que permite explorar y comparar diversas configuraciones hasta

identificar la que minimiza el costo total.

Estas fases antes descritas, se ilustran en la Figura 7.2, la cual se presenta a continuación:

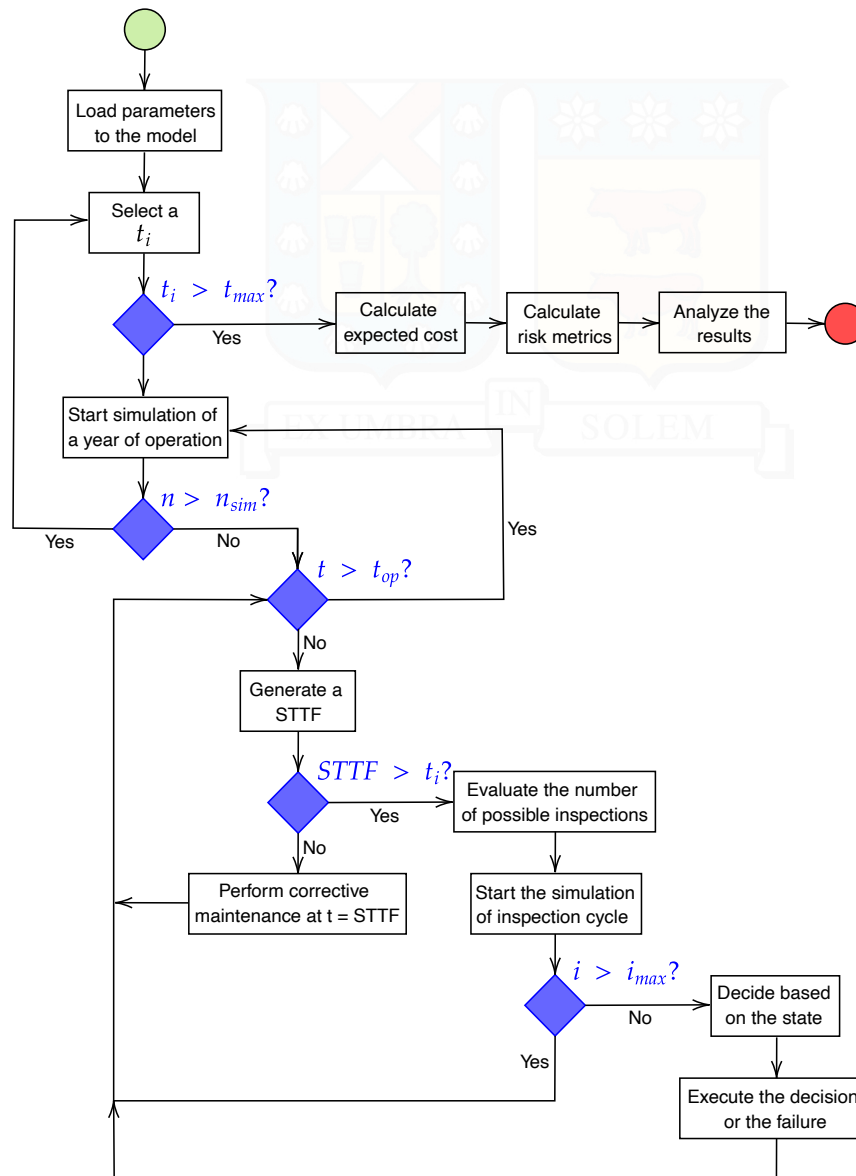


Figura 7.2: Diagrama de flujo de proceso para el modelo de simulación estocástica. Fuente: Elaboración propia.

7.3 Parámetros del Modelo

Para representar el entorno operativo, se definen los parámetros del modelo que actúan como insumos esenciales en la simulación. Estos parámetros incluyen costos asociados, tiempos de mantenimiento, intervalos de inspección, y distribuciones probabilísticas que modelan el

deterioro del equipo. A continuación, se detallan los parámetros considerados:

No.	Notación	Descripción
1	α	Parámetro de escala de la distribución Weibull.
2	β	Parámetro de forma de la distribución Weibull.
3	T	Tiempo total de operación del equipo en un año.
4	$RT_{m,k}$	Tiempo de reparación tipo m en la intervención k .
5	RT_j	Tiempo que tarda en realizarse una inspección j .
6	$CM_{m,k}$	Costo de mantenimiento tipo m en la intervención k .
7	CR_k	Costo del repuesto requerido en la intervención k .
8	CD_k	Costo de ineficiencia por hora de la intervención k .
9	T_i	Tiempo entre inspecciones a evaluar, indexado por $i = 1, \dots, I $.
10	n	Número de simulaciones.
11	$DSPM_{l,i}$	Matriz probabilística de deterioro como insumo del modelo.

Tabla 7.1: Parámetros del Modelo. Fuente: Elaboración Propia.

Los parámetros α y β (1 y 2) son fundamentales para caracterizar el comportamiento del sistema mediante la distribución Weibull, ampliamente utilizada en el análisis de confiabilidad. El parámetro α representa la escala de los tiempos hasta falla, indicando la duración característica del componente, mientras que β determina la forma de la distribución.

El horizonte de análisis se define mediante T (3), que corresponde al tiempo total de operación del equipo, usualmente representado en un año. Este parámetro es clave para calcular métricas acumulativas, como el costo total esperado y la disponibilidad operativa.

Los tiempos asociados a las actividades de mantenimiento y revisión se modelan a través de $RT_{m,k}$ y RT_j (4 y 5). $RT_{m,k}$ especifica la duración de reparaciones de tipo m en la intervención k , mientras que RT_j describe el tiempo necesario para realizar cada inspección. Estos valores permiten evaluar cómo los tiempos de intervención afectan la disponibilidad del sistema.

En términos de costos, $CM_{m,k}$, CR_k y CD_k (6, 7 y 8) abarcan los costos directos de mantenimiento, los costos de repuestos y los costos asociados a la ineficiencia causada por el tiempo de inactividad durante las intervenciones de mantenimiento o fallas no programadas. Estos parámetros son cruciales para el análisis económico del sistema bajo diferentes estrategias de inspección.

Los parámetros T_i y n (9 y 10) están relacionados con la simulación. T_i representa los distintos intervalos entre inspecciones evaluados, mientras que n corresponde al número de simulaciones ejecutadas. Estas simulaciones permiten capturar la variabilidad inherente al sistema y evaluar el desempeño de cada estrategia bajo condiciones estocásticas.

Finalmente, la matriz $DSPM_{l,i}$ (11) se propone como un insumo clave del modelo para representar las probabilidades de encontrar el componente en ciertos niveles de deterioro tras cada inspección. Este parámetro facilita la modelación detallada del componente en estudio al

someterse a la política de mantenimiento propuesta en el presente trabajo de investigación y será descrito en mayor detalle en secciones posteriores.

En conjunto, estos parámetros forman la base del modelo, permitiendo una representación realista del sistema y una evaluación detallada de las diferentes frecuencias de inspección propuestas, de modo de hallar aquella que minimice el costo esperado.

7.4 Determinación de Parámetros Estocásticos

La incertidumbre inherente en los sistemas de mantenimiento y operación de equipos exige la consideración de parámetros estocásticos en la modelación. Los valores de costos y tiempos asociados a cada actividad de inspección y mantenimiento son inciertos, ya que dependen de diversos factores externos como el estado del equipo, la disponibilidad de repuestos y personal, y la eficiencia operativa en el momento de la intervención. En este contexto, los parámetros considerados en el modelo, tales como los costos de inspección, repuestos, tiempos de reparación y costos de ineficiencia, son tratados como variables aleatorias.

Los siguientes parámetros se modelan bajo distribuciones normales, con sus respectivas medias μ y desviaciones estándar σ :

CI_j	CR_k	CD_k	$CM_{m,k}$	$RT_{m,k}$
$\mathcal{N}(\mu_{CI}, \sigma_{CI})$	$\mathcal{N}(\mu_{CR}, \sigma_{CR})$	$\mathcal{N}(\mu_{CD}, \sigma_{CD})$	$\mathcal{N}(\mu_{CM}, \sigma_{CM})$	$\mathcal{N}(\mu_{RT}, \sigma_{RT})$

Tabla 7.2: Parámetros modelados con distribuciones normales.

Cada uno de estos parámetros sigue una distribución normal, donde μ es la media esperada del parámetro, y σ representa la variabilidad asociada. Este enfoque es adecuado debido a que las distribuciones normales reflejan la variabilidad natural alrededor de un valor promedio, lo cual es común en el comportamiento de costos y tiempos en operaciones de mantenimiento.

La determinación de los parámetros μ y σ para cada componente puede llevarse a cabo mediante la recopilación de datos históricos o mediante la consulta con expertos en el área. Para costos de inspección (CI_j) y costos de mantenimiento ($CM_{m,k}$), es posible emplear datos contables o informes de mantenimiento previos. Los tiempos de reparación ($RT_{m,k}$) y los costos de ineficiencia (CD_k) se pueden estimar con base en registros de intervenciones anteriores y análisis de tiempos de inactividad. Por último, los costos de repuestos (CR_k) pueden obtenerse directamente de los contratos de proveedores o los registros de compras históricas.

Al utilizar estas distribuciones probabilísticas, el modelo captura de manera más realista la variabilidad en los costos totales de mantenimiento, permitiendo evaluar el impacto de esta incertidumbre en la toma de decisiones sobre la frecuencia de inspecciones y la planificación de mantenimiento. De este modo, se busca minimizar no solo el costo promedio, sino también mitigar el riesgo asociado con escenarios extremos, asegurando una operación más eficiente y confiable.

7.5 Criterio de Optimización

El criterio de optimización del modelo se centra en minimizar el valor esperado del costo total de mantenimiento (CT). Este costo incluye los componentes asociados a inspecciones, mantenimientos preventivos, así como los costos derivados de fallas inesperadas. La formulación del criterio de optimización se presenta en la Ecuación 7.1, que detalla la composición del costo total esperado:

$$\begin{aligned} \text{mín } E[C(t)] = & \sum_{j \in J} CI_j \cdot RT_j + \sum_{k \in K} \left[CR_k + \right. \\ & \left. \left(\sum_{m=1}^2 (y_k \cdot CD_k + z_k \cdot \eta \cdot CD_k) \cdot RT_{m,k} + CD_k \cdot RT_{3,k} \right) + \right. \\ & \left. \sum_{m \in M} CM_k \cdot RT_{m,k} \right] \end{aligned} \quad (7.1)$$

Los elementos de la ecuación se describen a continuación:

- J : Conjunto de inspecciones realizadas durante el período de estudio.
- K : Conjunto de intervenciones realizadas durante el período de estudio.
- M : Conjunto de tipos de intervenciones de mantenimiento (preventivo, correctivo, etc.).
- CI_j : Costo asociado a la inspección j .
- CR_k : Costo de repuestos requeridos para la intervención k .
- CD_k : Costo de ineficiencia relacionado con el tiempo de inactividad durante la intervención k , ajustado por la disponibilidad del programador.
- y_k : Variable binaria que toma el valor de 1 si el programador no está disponible para gestionar el mantenimiento de k , y 0 en caso contrario.
- z_k : Variable binaria que toma el valor de 1 si el programador está disponible para gestionar el mantenimiento de k , y 0 en caso contrario.
- CM_k : Costo de mantenimiento asociado a la intervención k .
- RT_j : Tiempo que tarda en realizarse la inspección j .
- $RT_{m,k}$: Tiempo de reparación correspondiente al tipo de mantenimiento m en la intervención k .

Las variables y_k y z_k desempeñan un papel fundamental en la modelación del costo de ineficiencia. Dichas variable permite considerar la capacidad del programador para planificar las actividades de mantenimiento de manera eficiente, de modo que el impacto de la indisponibilidad sea mitigado. La contribución de CD_k al costo total depende de si el programador está o no

disponible, de modo que cuando el programador no está disponible todo el costo de ineficiencia representado por CD_k afecta al costo de mantenimiento del componente en estudio, mientras que cuando el programador está disponible, el costo de ineficiencia se ajusta en base a un factor, lo cual puede representarse en la siguiente relación:

$$CD_k = CD'_k \cdot \eta \quad (7.2)$$

Donde:

- CD'_k : Costo base de ineficiencia asociado a la duración de la intervención k y al respectivo costo por hora asociado a la ineficiencia.
- η : Factor de ajuste que representa la disminución en el costo de ineficiencia debido a la planificación oportuna y eficiente del programador.

En base a lo anterior, las variables binarias definidas, permiten que se active un caso o el otro, dependiendo de la disponibilidad del programador, lo cual permite que el modelo sea más robusto y se ajuste a la realidad de los entornos industriales, donde se puede planificar o agrupar las actividades de mantenimiento de forma eficiente, de modo de mitigar los tiempos de detención sujetos a las diferentes actividades de mantenimiento preventivo que se deseen realizar.

La ecuación (7.1) refleja un modelo optimizado que considera los costos asociados a inspecciones, repuestos, ineficiencia y tiempos de reparación, incluyendo las interacciones entre la disponibilidad del programador y los costos de ineficiencia. Este enfoque garantiza una representación más realista de los costos totales en escenarios industriales complejos.

En el caso de que $z_k = 0$, el costo de ineficiencia CD_k contribuye en su totalidad al costo total esperado, ya que la falta de disponibilidad del programador impide la implementación de medidas de mitigación.

Finalmente, el modelo utiliza simulación estocástica para evaluar el impacto de diferentes intervalos de inspección (t_i) sobre el costo total esperado. Este enfoque permite identificar el intervalo óptimo que minimiza los costos totales al equilibrar la frecuencia de inspecciones con los costos asociados a fallas y mantenimientos no planificados. De este modo, se busca proporcionar una herramienta robusta para la toma de decisiones en la gestión de mantenimiento.

7.6 Matriz de Probabilidad de Estado de Deterioro (DSPM)

Como se ha mencionado en capítulos anteriores, el modelo propuesto se alimenta de información probabilística que permite estimar el comportamiento del equipo bajo distintos escenarios de inspección y mantenimiento. Dado esto, como una de las entradas se propone la **Matriz de Probabilidad de Estado de Deterioro (DSPM)**, por sus siglas en inglés), como una herramienta clave para modelar el comportamiento probabilístico del deterioro de un equipo a lo largo del tiempo. Aunque la implementación y desarrollo completo de esta matriz se

explorará en trabajos futuros, aquí se presenta su conceptualización, así como las posibles fuentes de obtención de los valores que la conforman.

La DSPM está diseñada para capturar la probabilidad de que un equipo se encuentre en distintos niveles de deterioro en función del tiempo y la estructura general de esta matriz es la siguiente:

$$\begin{array}{c}
 \text{Lvl 1} \\
 \text{Lvl 2} \\
 \text{Lvl 3} \\
 \text{Lvl 4} \\
 \vdots \\
 \text{Lvl } l
 \end{array}
 DSPM_{l,i} =
 \begin{array}{c}
 t_1 \quad t_2 \quad \cdots \quad t_i \\
 \left[\begin{array}{cccc}
 P_{1,1} & P_{1,2} & \cdots & P_{1,i} \\
 P_{2,1} & P_{2,2} & \cdots & P_{2,i} \\
 P_{3,1} & P_{3,2} & \cdots & P_{3,i} \\
 P_{4,1} & P_{4,2} & \cdots & P_{4,i} \\
 \vdots & \vdots & \ddots & \vdots \\
 P_{l,1} & P_{l,2} & \cdots & P_{l,i}
 \end{array} \right]
 \end{array}
 \quad (7.3)$$

Donde:

- $P_{l,i}$ representa la probabilidad de que el equipo se encuentre en el nivel de deterioro l en el tiempo t_i .
- Los niveles de deterioro (**Lvl**) van desde un estado óptimo (**Lvl 1**) hasta el máximo nivel de deterioro, que representa la falla total del equipo.
- Los tiempos t_i son intervalos discretos en los que se evalúa la condición del equipo.

Esta matriz no solo es una representación de estados, sino una herramienta para comprender y prever la evolución del deterioro, permitiendo tomar decisiones informadas sobre los intervalos de inspección y las estrategias de mantenimiento.

7.6.1. Fuentes para la Obtención de la DSPM

Las probabilidades que componen la DSPM pueden obtenerse a partir de diferentes métodos, adaptados a la disponibilidad de datos y las características del sistema bajo estudio. Entre las opciones más relevantes se encuentran:

- **Análisis de datos históricos:** El registro de inspecciones y mantenimientos pasados proporciona información empírica sobre la frecuencia y las condiciones en que el equipo alcanzó ciertos niveles de deterioro. Este enfoque es especialmente útil cuando se dispone de un conjunto robusto de datos históricos.
- **Consulta a expertos:** En ausencia de datos históricos suficientes, el conocimiento cualitativo de expertos en el sistema puede ser una fuente clave. A través de entrevistas, encuestas o talleres participativos, se pueden estimar probabilidades iniciales basadas en su experiencia y juicio profesional.

- **Modelos de simulación estocástica:** Estos modelos permiten generar trayectorias probabilísticas del deterioro del equipo, incorporando incertidumbre y variabilidad en la evolución de los estados. Herramientas como Monte Carlo o modelos de Markov pueden ser útiles.
- **Técnicas de Machine Learning:** Modelos predictivos, como redes neuronales o algoritmos de clasificación, pueden entrenarse con datos históricos para estimar la probabilidad de que el equipo o componente en estudio se encuentre en un respectivo nivel de deterioro.

7.6.2. Futuro Desarrollo de la DSPM

Si bien esta investigación propone la DSPM como una herramienta fundamental, su implementación detallada y validación serán abordadas en estudios futuros. Estas investigaciones se centrarán en:

- Refinar los métodos de obtención de probabilidades, combinando técnicas cuantitativas y cualitativas.
- Validar la matriz mediante casos de estudio reales.
- Explorar su integración con modelos avanzados de simulación y optimización.

En resumen, se cree que la DSPM puede convertirse en un componente interesante para fortalecer los modelos de simulación y optimización en la gestión del mantenimiento.

7.7 Tiempo hasta la Falla Simulado (STTF)

El **Tiempo hasta la Falla Simulado (STTF)**, por sus siglas en inglés) se define como una métrica clave para el desarrollo del modelo de simulación estocástica planteado, ya que permite predecir el tiempo que transcurre hasta que el equipo en estudio podría eventualmente fallar. Esta predicción es fundamental para planificar intervenciones de mantenimiento y optimizar la disponibilidad del equipo.

Para modelar el STTF, se utiliza la distribución Weibull, que es ampliamente empleada en el análisis de fiabilidad y en el estudio del comportamiento del tiempo hasta la falla de componentes y sistemas [50, 51]. Se emplea la función inversa de la distribución acumulativa (CDF). Esta función permite calcular el tiempo hasta la falla a partir de una probabilidad aleatoria que se denotará como \mathbb{P}_f generada uniformemente en el intervalo $(0, 1)$. La inversa de la función de Weibull está dada por la siguiente expresión:

$$STTF = \alpha (-\ln(1 - \mathbb{P}_f))^{1/\beta} \quad (7.4)$$

Donde $STTF$, como se mencionó antes, representa el tiempo hasta la falla, α es el parámetro de escala y β es el parámetro de forma. Estos parámetros son esenciales para caracterizar el

comportamiento del equipo y se pueden obtener de varias maneras:

- **Análisis de Datos Históricos:** Se pueden utilizar datos de fallas anteriores del equipo para estimar los parámetros. Se ajusta la distribución Weibull a estos datos mediante métodos estadísticos como el método de máxima verosimilitud o el método de mínimos cuadrados. $\hat{\lambda}$
- **Ajustes de Curva:** Este enfoque implica la utilización de técnicas específicas de ajuste de curvas para adaptar la distribución Weibull a los datos de fallas, optimizando los parámetros α y β para una mejor representación del comportamiento del equipo.
- **Técnicas de Machine Learning:** Se pueden aplicar algoritmos de aprendizaje automático para modelar los tiempos hasta la falla utilizando conjuntos de datos históricos, permitiendo una estimación más precisa de los parámetros.

Para simular los tiempos hasta la falla, se pueden generar valores aleatorios a partir de la distribución Weibull utilizando los parámetros α y β . Este proceso permite crear un conjunto de datos que representan el comportamiento del equipo a lo largo del tiempo y facilita el análisis de confiabilidad y el desarrollo de estrategias de mantenimiento preventivo y predictivo. Esto, en conjunto con la simulación de Monte Carlo, los parámetros estocásticos definidos y la evaluación de distintos intervalos de inspección, proporciona una herramienta poderosa para la toma de decisiones en la gestión del mantenimiento.

8 | Aplicación Numérica

En este capítulo, se presenta un ejemplo numérico que tiene como objetivo ilustrar el funcionamiento del modelo de simulación estocástica desarrollado. A través de este ejemplo, se pretende demostrar la capacidad del modelo para optimizar la frecuencia de inspección y las decisiones de mantenimiento asociadas a un componente crítico sujeto a fallas por concepto de su operación.

El ejemplo permite visualizar cómo las diferentes combinaciones de parámetros y decisiones afectan el comportamiento del sistema a lo largo del tiempo, así como los costos asociados a las inspecciones y mantenimientos. Además, el caso desarrollado muestra cómo el modelo gestiona la incertidumbre inherente a los tiempos hasta la falla (STTF) y los niveles de deterioro del componente.

A continuación, se describen las especificaciones del ejemplo numérico y los parámetros utilizados para su resolución.

8.1 Especificaciones del Ejemplo Numérico

En esta sección se detallan las configuraciones del ejemplo numérico utilizado para demostrar el funcionamiento del modelo de simulación estocástica desarrollado, con el objetivo de analizar cómo las distintas combinaciones de parámetros afectan las decisiones de mantenimiento y el costo total del sistema, proporcionando una comprensión más profunda del comportamiento del modelo.

El modelo considera las siguientes características clave:

Niveles Deterioro	Tipos Mantenimiento	STTF
Se considerarán l niveles de deterioro, con $l = \{1, \dots, 4\}$. Donde $l = 1$ indica que el equipo se encuentra en estado óptimo y $l = 4$ implica una falla del equipo.	Existen m tipos de mantenimiento, con $m = \{1, 2, 3\}$. Donde $m = 1$ corresponde a mantenimiento preventivo Tipo 1, $m = 2$ a preventivo Tipo 2 y $m = 3$ a Correctivo.	Los tiempos hasta la falla siguen una distribución Weibull con un α y β representativos del equipo, lo que permite estimar la ocurrencia de eventos y planificar el mantenimiento.

Tabla 8.1: Especificaciones del ejemplo numérico.

El análisis se realiza considerando un horizonte temporal de $T = 8760$ horas, que corresponde al tiempo total de operación del equipo en un año bajo un régimen continuo (24/7), permitiendo capturar completamente el ciclo de vida operativo típico del equipo dentro de un año calendario.

Por otro lado, las frecuencias de inspección evaluadas corresponden a un intervalo discreto definido por $t_i = [20, 450]$, con incrementos de 10 horas, lo cual facilita analizar el impacto de diferentes frecuencias de inspección en el desempeño del equipo.

Los *STTF* se generan aleatoriamente en cada simulación utilizando la distribución Weibull con parámetros $\alpha = 250$ y $\beta = 4$, valores que se encargarán de caracterizar el equipo estudiado, buscando que los tiempos de falla representen al componente en su contexto operativo.

Finalmente, para garantizar la robustez de los resultados, se realizan $n = 10000$ simulaciones por cada frecuencia de inspección, con la finalidad de obtener resultados estadísticamente sólidos, que son fundamentales para evaluar y optimizar la política de mantenimiento propuesta mediante el modelo de simulación estocástica desarrollado.

8.2 Parámetros Estocásticos del Problema

Los parámetros estocásticos presentados en las Tablas 8.2 y 8.3 proporcionan las variables clave para modelar la incertidumbre y la dinámica del sistema en el ejemplo numérico. Estas variables abarcan tanto los tiempos de reparación como los costos asociados, los cuales son fundamentales para la simulación y análisis del modelo.

$RT_{1,k}$	$RT_{2,k}$	$RT_{3,k}$	RT_j
$0.25 \cdot \mu_{3,k}$	$0.5 \cdot \mu_{3,k}$	$\mathcal{N}(\mu_{3,k} = 9, \sigma_{3,k} = 2)$	1

Tabla 8.2: Tiempos de reparación utilizados en el ejemplo numérico.

En la Tabla 8.2, se presentan los tiempos de reparación utilizados en el modelo. El tiempo de reparación preventivo tipo 1 ($RT_{1,k}$) y tipo 2 ($RT_{2,k}$) son proporciones de la media del tiempo de reparación correctivo ($\mu_{3,k}$). Estos tiempos de reparación preventiva se definen como $0.25 \cdot \mu_{3,k}$ para el tipo 1 y $0.5 \cdot \mu_{3,k}$ para el tipo 2, donde $\mu_{3,k} = 9$ horas es la media del tiempo de reparación correctiva, y $\sigma_{3,k} = 2$ horas es su desviación estándar. Por otro lado, el tiempo de inspección (RT_j) es determinístico y se establece en una hora.

CM_k	CR_k	CD_k
$\mathcal{N}(\mu_{CM} = 40, \sigma_{CM} = 5)$	$\mathcal{N}(\mu_{CR} = 200, \sigma_{CR} = 20)$	$1000 \cdot \mathcal{N}(\mu_{CM} = 40, \sigma_{CM} = 5)$

Tabla 8.3: Costos de reparación utilizados en el ejemplo numérico.

La Tabla 8.3 muestra los parámetros económicos asociados a los costos de reparación, inspección, ineficiencia y repuestos. El costo de la mano de obra o costo de reparación (CM_k) y el costo de los repuestos (CR_k) están modelados como variables aleatorias con distribuciones normales. El costo de la mano de obra tiene una media de $\mu_{CM} = 40$ y una desviación estándar de $\sigma_{CM} = 5$. De forma similar, el costo de los repuestos se modela con una distribución normal con su respectiva media y desviación estándar que se puede apreciar en la Tabla 8.3.

Finalmente, el costo de ineficiencia (CD_k) se establece en función del costo de reparación CM_k , específicamente multiplicando dicho valor por 1000, reflejando su relación con los costos operativos y de mantenimiento.

$$DPMS_{l,i} = \begin{matrix} & t_1 & t_2 & t_3 & t_4 & t_5 & \cdots & t_{44} \\ \text{Lvl 1} & 0.8 & 0.791 & 0.773 & 0.754 & 0.737 & \cdots & 0.036 \\ \text{Lvl 2} & 0.15 & 0.156 & 0.163 & 0.169 & 0.175 & \cdots & 0.054 \\ \text{Lvl 3} & 0.05 & 0.053 & 0.064 & 0.077 & 0.088 & \cdots & 0.91 \end{matrix} \quad (8.1)$$

En el caso de la matriz $DPMS_{l,i}$, que describe la probabilidad de que el sistema se encuentre en cada nivel de deterioro **Lvl 1** en función del tiempo transcurrido entre inspecciones t_i , se observa que para el primer nivel de deterioro (**Lvl 1**), la probabilidad comienza alta (0.8 en t_1) y disminuye conforme aumenta el tiempo de inspección, alcanzando un valor de 0.036 en t_{44} . Este comportamiento refleja que el sistema está en su estado inicial de deterioro y, por lo tanto, las probabilidades de este nivel de deterioro van decreciendo con el tiempo.

Para el nivel de deterioro **Lvl 2**, la probabilidad inicial es baja (0.15) y aumenta a medida que transcurre el tiempo, para luego volver a disminuir hasta llegar a valores cercanos a 0.054. Esto indica que el sistema está en un proceso intermedio de deterioro, donde la probabilidad de detectar fallas se incrementa paulatinamente a lo largo del tiempo, pero luego vuelve a disminuir porque se hace más probable que el componente se encuentre en un nivel de deterioro mayor.

El tercer nivel de deterioro **Lvl 3** refleja una condición avanzada de deterioro, pero no una falla completa del sistema. Este nivel comienza con una probabilidad baja (0.05) y su probabilidad crece con el tiempo, alcanzando un valor considerable de 0.91 en el último tiempo de inspección considerado. Cabe destacar que el nivel **Lvl 4** no está incluido en la matriz, ya que representa el estado de falla, el cual solo se alcanza cuando las inspecciones no logran detectar el deterioro a tiempo, lo que implica que el sistema ha llegado a un nivel crítico.

9 | Resultados

El presente capítulo expone de manera detallada los resultados obtenidos mediante la aplicación numérica del modelo de simulación estocástica propuesto. En primera instancia, se presentan los resultados basados en el cálculo del valor esperado, los cuales permiten identificar la frecuencia de inspección óptima que minimiza el costo total esperado, conforme al criterio de optimización previamente establecido.

Posteriormente, se realiza un análisis de ciertas métricas de riesgo, con el objetivo de complementar la decisión basada en el valor esperado y proporcionar una perspectiva más robusta para la toma de decisiones. Finalmente, se incluye un análisis de sensibilidad que evalúa la influencia de los parámetros clave del modelo en la variabilidad del costo total esperado y en la determinación de la frecuencia óptima.

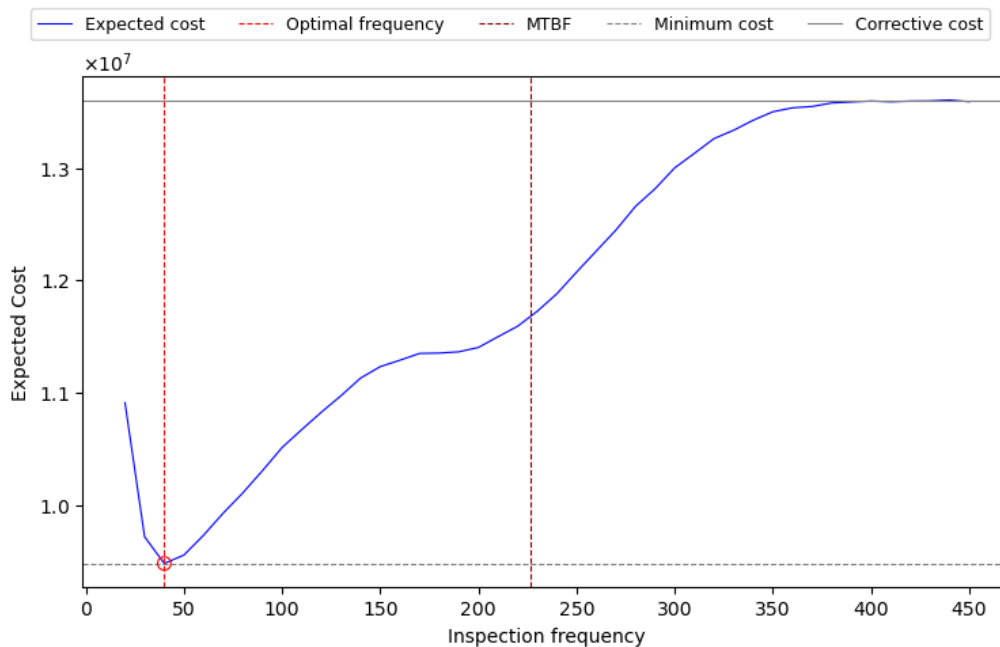


Figura 9.1: Frecuencia de Inspección Óptima basada en el Valor Esperado.

La Figura 9.1 muestra la relación entre la frecuencia de inspección y el valor esperado de los costos totales de mantenimiento, destacando el punto correspondiente a la frecuencia óptima. La curva principal ilustra cómo los costos esperados varían según la frecuencia de inspección, presentando un mínimo global que indica la estrategia más eficiente. Este mínimo, identificado con una línea discontinua roja, representa la frecuencia de inspección que equilibra de manera efectiva los costos asociados a las inspecciones, el mantenimiento preventivo y las fallas no detectadas.

Adicionalmente, se incluye el tiempo medio entre fallas (MTBF), que permite analizar el comportamiento de los costos en frecuencias superiores a este valor. Se observa que, al superar el MTBF, los costos de mantenimiento incrementan notablemente, alcanzando niveles similares a los costos asociados a adoptar una política de mantenimiento correctivo. Esto evidencia que inspeccionar a frecuencias mayores al MTBF no resultaría beneficioso ni eficiente en términos económicos.

Finalmente, es posible señalar que el comportamiento general de la curva revela que los costos esperados tienden a ser altos cuando la frecuencia de inspección es muy baja, debido a un incremento en el número de inspecciones, y también cuando la frecuencia es excesivamente alta, debido al predominio de los costos de fallas no planificadas. Este análisis resalta la importancia de identificar una frecuencia de inspección adecuada, que permita minimizar los costos totales mientras se mantiene un equilibrio entre las actividades de inspección y mantenimiento.




Figura 9.2: Comportamiento de los costos en función de la frecuencia de inspección.




Figura 9.3: Cantidad de intervenciones en función de la frecuencia de inspección.

La Figura 9.2 analiza los componentes individuales de los costos esperados, agrupados en tres categorías principales: costos de inspección, costos de ineficiencia y costos de reparación. En el primer gráfico, se observa cómo los costos de inspección disminuyen de manera exponencial al incrementarse la frecuencia de inspección. Esto se explica porque una mayor frecuencia implica una reducción en la cantidad total de inspecciones posibles, lo que resulta en menores costos asociados a esta actividad.

El segundo gráfico muestra la relación no lineal entre los costos de ineficiencia y la frecuencia de inspección. Estos costos alcanzan un mínimo cercano a la frecuencia óptima antes de incrementarse nuevamente. Este comportamiento indica que tanto una frecuencia de inspección

insuficiente como excesiva puede generar tiempos de inactividad significativos. La insuficiencia de inspecciones puede llevar a fallas no detectadas, mientras que el exceso puede derivar en inspecciones redundantes, ambas situaciones con un impacto adverso en los costos. Este análisis resalta la importancia de encontrar un equilibrio que minimice dichos periodos de inactividad.

Por último, el tercer gráfico descompone los costos de reparación en tres tipos: mantenimientos preventivos de tipo 1 (PM tipo 1), mantenimientos preventivos de tipo 2 (PM tipo 2) y mantenimientos correctivos (CM). Los costos asociados a los mantenimientos preventivos disminuyen de forma sostenida a medida que aumenta la frecuencia de inspección. Este descenso refleja que, a frecuencias más altas, se reduce la capacidad de detectar fallas de manera anticipada mediante inspecciones, lo que provoca un predominio de los mantenimientos correctivos. En contraste, los costos de mantenimiento correctivo muestran un comportamiento inverso, aumentando en gran medida a frecuencias más altas debido a la mayor ocurrencia de fallas no planificadas. Este análisis es otro indicador de la importancia de determinar una frecuencia de inspección adecuada, que permita reducir las intervenciones de mantenimiento correctivo y mitigar su impacto en los costos totales de mantenimiento.

Adicionalmente, la Figura 9.3 explora el impacto de la frecuencia de inspección en el número de intervenciones requeridas. En el primer gráfico se muestra que el número de inspecciones disminuye exponencialmente con la reducción de la frecuencia, mientras que en el segundo gráfico se observa un comportamiento similar para los mantenimientos preventivos, tanto de tipo 1 como de tipo 2. En contraste, el tercer gráfico evidencia que el número de mantenimientos correctivos incrementa de manera significativa a frecuencias bajas, enfatizando nuevamente el costo operativo asociado a la falta de inspecciones regulares. Este análisis conjunto revela la relación directa entre las decisiones de inspección y las demandas de intervenciones futuras, permitiendo una mejor planificación de recursos.

En resumen, los resultados obtenidos destacan la importancia de adoptar una estrategia óptima de inspección basada en el análisis de los costos totales esperados y la frecuencia de fallas del sistema. Este enfoque permite no solo minimizar los costos asociados, sino también reducir el impacto operativo de las fallas no detectadas, logrando así un equilibrio eficiente entre el mantenimiento preventivo y correctivo.

9.1 Métricas de Riesgo

En esta sección se evaluaron las métricas de riesgo asociadas a las diferentes frecuencias de inspección, considerando la probabilidad de fallas no detectadas y los costos derivados de eventos inesperados. Los resultados permitieron identificar cómo el riesgo operativo se reduce al implementar una frecuencia de inspección adecuada, equilibrando los costos asociados.

La Figura 9.4 ilustra el comportamiento del VaR y CVaR para cada frecuencia de inspección. El gráfico revela que, a medida que se incrementa la frecuencia de inspección, los costos en los escenarios más adversos tienden a elevarse, lo que puede inducir a un ligero cambio

en la frecuencia óptima de inspección. Este patrón sugiere que, en condiciones de mayor riesgo, donde los eventos extremos son más probables, podría ser más prudente adoptar una frecuencia de inspección más baja. A pesar de que el valor esperado de los costos podría sugerir una frecuencia óptima mayor, los resultados de VaR y CVaR muestran que reducir la frecuencia de inspección, acercándola a un valor más conservador, podría resultar en una mitigación más efectiva de los riesgos asociados a los costos extremos. De esta manera, las métricas de riesgo ofrecen un enfoque más cauteloso, recomendando una frecuencia de inspección menor para protegerse contra posibles pérdidas significativas, aunque el valor esperado sugiera lo contrario.

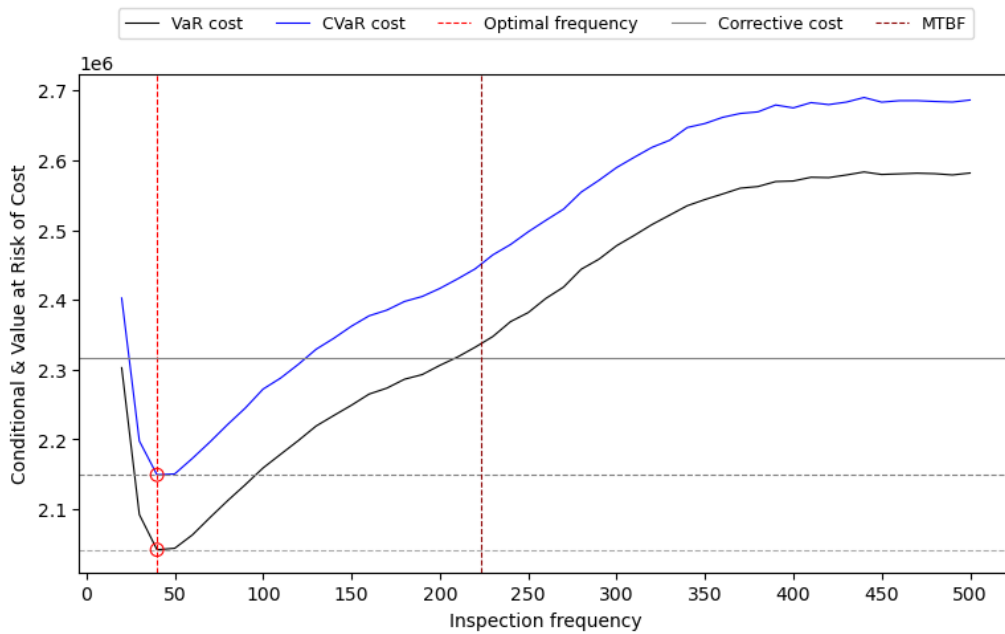


Figura 9.4: Gráfico de VaR y CVaR para cada frecuencia de inspección.

En la Figura 9.5 se presentan dos gráficos complementarios que profundizan en el análisis de la semidesviación, un indicador que captura la variabilidad de los costos en la cola superior de la distribución, es decir, en los escenarios de costos más elevados. El gráfico de la izquierda muestra cómo la semidesviación varía con la frecuencia de inspección. Se observa que, cerca del tiempo medio entre fallas (MTBF), la semidesviación alcanza su valor máximo. Este fenómeno puede explicarse porque a frecuencias cercanas al MTBF, la probabilidad de fallas no detectadas o eventos imprevistos aumenta, lo que incrementa la dispersión de los costos hacia valores más altos. Aunque los costos de mantenimiento preventivo en estas frecuencias pueden ser relativamente bajos, el riesgo de incurrir en fallas no planificadas y, por ende, en elevados costos correctivos, es considerablemente mayor, lo que resulta en una semidesviación más alta.

El gráfico de la derecha presenta un análisis de dominancia de semidesviación frente al costo esperado, permitiendo identificar las frecuencias de inspección que son dominantes en términos de eficiencia. Las frecuencias de inspección dominantes son aquellas que se encuentran

cerca del punto ideal, es decir, aquellas que logran un buen equilibrio entre el costo esperado y la variabilidad de los costos. En contraste, las frecuencias situadas más alejadas del nadir (punto más bajo en el gráfico) son menos eficientes, ya que, aunque reducen el costo esperado, incrementan de manera desproporcionada la semidesviación, lo que implica un mayor riesgo de enfrentar costos elevados. Este análisis de dominancia subraya la importancia de seleccionar una frecuencia de inspección que no solo minimice el costo esperado, sino que también minimice la exposición a la variabilidad de los costos. De este modo, se busca una solución que no solo sea económicamente eficiente, sino que también sea robusta frente a la incertidumbre, evitando picos de costos que puedan tener un impacto negativo en la operación.

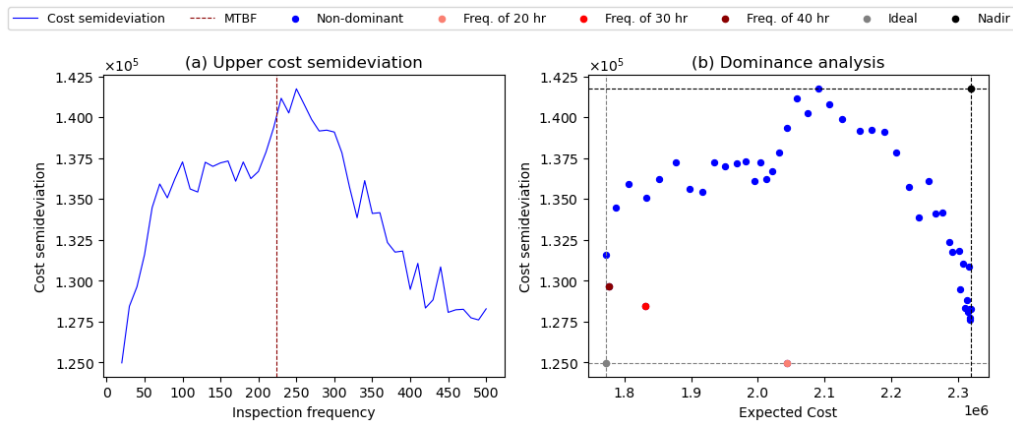


Figura 9.5: Análisis de semidesviación y dominancia de semidesviación vs costo esperado.

9.2 Análisis de Sensibilidad

El análisis de sensibilidad se llevó a cabo utilizando el método de Sobol, una técnica ampliamente reconocida por su capacidad para descomponer y cuantificar la influencia de los parámetros del modelo sobre la variabilidad del costo total esperado.

Los resultados de este análisis son presentados en la Figura 9.6 y ofrecen una visión detallada de la importancia relativa de cada parámetro y sus interacciones.

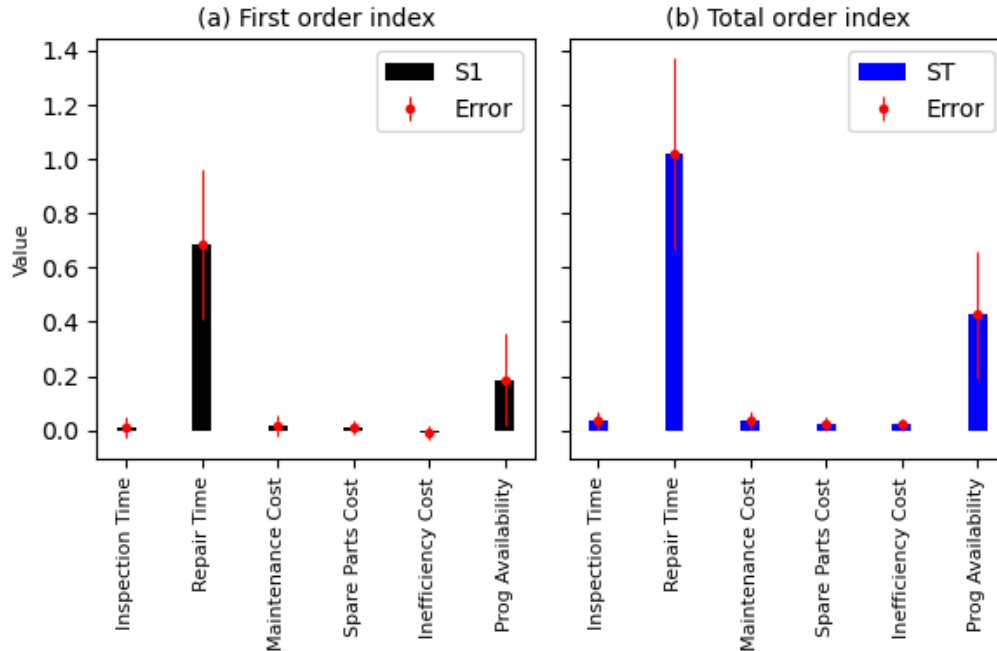


Figura 9.6: Resultados Análisis de Sensibilidad Global

De los resultados obtenidos, se observa que la variable con mayor influencia es el **tiempo de reparación**, el cual presenta un índice de primer orden de 0.687 y un índice de orden total de 1.018, indicando que no solo es el factor más relevante de manera directa, sino también a través de sus interacciones con otros parámetros. Esto sugiere que cualquier incertidumbre en el tiempo de reparación tiene un impacto significativo en la variabilidad del costo total, lo que resalta la importancia de contar con estimaciones precisas para esta variable.

Por otro lado, la **disponibilidad del programador** también muestra una contribución considerable, con un índice de primer orden de 0.187 y un índice de orden total de 0.426. Esto implica que la planificación efectiva de las actividades de mantenimiento y la potencial reducción de los costos asociados a los tiempos de inactividad tiene un efecto moderado pero significativo tanto de manera directa como a través de interacciones con otros factores. Este resultado resalta la relevancia de ser capaces de planificar de forma eficiente las actividades de mantenimiento ya que este aspecto puede influir de forma significativa en minimizar los costos de ineficiencia y, por ende, los costos totales de mantenimiento, mas aún en entornos operativos donde la ineficiencia juega un rol clave, como es el caso de la industria minera.

En contraste, variables como el **tiempo de inspección**, el **costo de mantenimiento** y el **costo de repuestos** tienen índices de sensibilidad mucho más bajos, con valores de primer orden que oscilan entre 0.010 y 0.015, y de orden total menores a 0.035. Aunque su influencia es limitada, su contribución no debe ser ignorada, especialmente en escenarios donde se busque optimizar el modelo de manera integral.

Cabe destacar que el **costo de ineficiencia** presenta un índice de primer orden negativo

(-0.011), lo cual podría deberse a efectos de colinealidad o a una interacción compleja con otras variables del modelo. Aunque su impacto directo es bajo, su índice de orden total de 0.021 indica que tiene un rol, aunque menor, en combinación con otros parámetros.

Los resultados obtenidos en este análisis son coherentes al considerar que el tiempo de reparación incide directamente en los costos de mantenimiento, ya que estos suelen calcularse en función de las horas requeridas para completar la reparación. Esto implica que un mayor tiempo de reparación conlleva un incremento proporcional en los costos asociados. Por su parte, la disponibilidad del programador afecta significativamente la eficiencia de las actividades de mantenimiento, lo que repercute directamente en los costos de ineficiencia. Estos costos, en ciertos entornos industriales, pueden representar una proporción considerable de los costos totales esperados, destacando su relevancia en el modelo.

Este análisis es crucial para identificar las áreas donde se deben priorizar los esfuerzos en la recolección de datos y calibración del modelo. En particular, se recomienda concentrarse en el tiempo de reparación y la disponibilidad programada, ya que son las variables con mayor influencia en la variabilidad del costo total esperado. Además, entender las interacciones entre estas variables puede contribuir a mejorar la robustez del modelo frente a la incertidumbre inherente en sistemas de mantenimiento complejos.

10 | Discusiones y conclusiones

El presente estudio tuvo como objetivo desarrollar una metodología basada en simulación estocástica para determinar la frecuencia óptima de inspección en políticas de mantenimiento que emplean inspecciones periódicas como estrategia clave. Este enfoque buscó minimizar los costos totales esperados derivados de la combinación de los costos de inspección, mantenimiento preventivo y correctivo, mientras se analizaba el impacto de la incertidumbre en los parámetros del modelo mediante herramientas avanzadas de análisis de sensibilidad. A lo largo del trabajo, se realizó una formulación detallada del modelo, acompañada de experimentación numérica, análisis de métricas de riesgo y evaluación de la influencia de los parámetros clave utilizando análisis de sensibilidad, como el método de Sobol.

Los resultados obtenidos permitieron identificar que el tiempo de reparación es el parámetro con mayor influencia en los costos totales esperados. Este hallazgo se explica por el hecho de que los costos de mantenimiento y de ineficiencia están directamente relacionados con la duración de las reparaciones o tiempo de inactividad, ya que mayores tiempos implican incrementos significativos en los costos asociados. Dado esto, reducir los tiempos de reparación mediante estrategias como la capacitación del personal, la mejora de los procesos de mantenimiento y la adopción de tecnologías avanzadas se presenta como una alternativa para mitigar estos costos. Además, la disponibilidad del programador se identificó como otro factor crítico, debido a su impacto en la eficiencia operativa y los costos de ineficiencia, lo que pone en evidencia la importancia de una gestión adecuada de los recursos humanos y tecnológicos y la correcta planificación de intervenciones de mantenimiento. Este mecanismo para representar la capacidad del encargado de la gestión de mantenimiento, sirve como un indicador de la eficiencia de las operaciones de mantenimiento y su impacto en los costos asociados.

El análisis de los costos totales mostró la existencia de una frecuencia de inspección óptima, donde se logra un equilibrio entre los costos asociados a las inspecciones recurrentes y los derivados de las fallas no detectadas. A frecuencias de inspección bajas, los costos son elevados debido al gran número de inspecciones realizadas, mientras que a frecuencias demasiado altas, los costos aumentan significativamente debido al predominio de los mantenimientos correctivos. Este comportamiento refuerza la necesidad de una estrategia de inspección que no solo minimice los costos esperados, sino que también sea sostenible y eficiente.

Adicionalmente, se incorporaron métricas de riesgo como la semi-desviación y el Valor en Riesgo Condicional (CVaR) para complementar el análisis basado en valor esperado. Estas métricas permitieron evaluar la variabilidad y los posibles escenarios extremos de los costos totales, proporcionando una visión más completa de los riesgos asociados a diferentes frecuencias de inspección. Los resultados mostraron que la frecuencia óptima identificada no solo minimiza los costos esperados, sino que también reduce el impacto financiero de eventos extremos, lo

que la convierte en una decisión robusta desde el punto de vista del riesgo.

Finalmente, el análisis de sensibilidad realizado mediante el método de Sobol permitió priorizar los parámetros del modelo según su impacto en la variabilidad de los costos totales. Este análisis confirmó que el tiempo de reparación y los costos de mantenimiento correctivo son los parámetros más influyentes, mientras que variables como los costos de repuestos tienen un impacto relativamente bajo. Estos resultados son fundamentales para orientar esfuerzos futuros en la obtención de datos más precisos sobre los parámetros clave y mejorar la robustez del modelo frente a la incertidumbre.

En resumen, este trabajo proporciona una herramienta robusta para la toma de decisiones en políticas de mantenimiento basadas en inspecciones periódicas. Además, establece un marco metodológico que combina análisis estocástico, métricas de riesgo y sensibilidad, ofreciendo un enfoque integral para abordar problemas similares en otros contextos industriales.

10.1 Trabajo Futuro

El presente estudio abre diversas oportunidades de mejora y extensión para el modelo desarrollado, tanto desde un punto de vista teórico como práctico. A continuación, se presentan algunas líneas de investigación y desarrollo futuro que podrían ampliar la aplicabilidad y robustez del enfoque propuesto:

Una primera área de mejora está relacionada con la matriz $DSPM$. En este trabajo, dicha matriz se introduce como un insumo ya definido, sin detallar el proceso de su construcción en un caso práctico. Una línea de investigación futura consiste en desarrollar una metodología clara y generalizada para calcular la matriz $DSPM$ en escenarios específicos. Esto implicaría explorar cómo obtener las probabilidades de encontrarse en cada estado de deterioro, integrando datos históricos, análisis estadístico y herramientas de simulación, para validarlas en un caso de estudio concreto. Además de la construcción de la matriz, podría ser relevante investigar como, a partir de la matriz $DSPM$, se pueden obtener los tiempos de transición entre estados, para abordar el problema a través de redes de Petri u otras herramientas similares.

Otra extensión relevante sería la evolución de un modelo monocomponente a uno multicomponente o un modelo monocomponente con distintos modos de falla. Esto permitiría abordar problemas con un enfoque sistémico, considerando la interacción entre múltiples componentes o la coexistencia de modos de falla diferentes que requieren estrategias de mantenimiento diferenciadas. Este tipo de modelo sería especialmente útil en sistemas complejos donde las dependencias entre componentes afectan significativamente el desempeño general.

Asimismo, se propone incorporar el concepto de inspecciones imperfectas. En el contexto industrial, no todas las inspecciones logran detectar fallas de manera efectiva; algunas pueden incluso empeorar el estado del sistema, mientras que otras podrían mejorar ligeramente la condición del componente o no tener ningún efecto. La inclusión de este aspecto en el modelo permitiría una representación más realista de las inspecciones y su impacto en la decisión

óptima de frecuencia.

Un aspecto adicional a considerar es la inclusión de retrasos en la planificación de actividades de mantenimiento. En escenarios reales, la programación de una intervención no es inmediata tras la detección de una falla, y en este intervalo podría ocurrir una falla no prevista. Incorporar este comportamiento en el modelo, a través de la simulación de ventanas de tiempo entre la inspección y la ejecución de la actividad de mantenimiento, incrementaría la validez práctica de las recomendaciones generadas.

Finalmente, explorar estrategias avanzadas de optimización para mejorar la eficiencia computacional del modelo sería otra línea de desarrollo interesante. En este trabajo, las simulaciones se realizaron de forma exhaustiva, pero técnicas como optimización bayesiana o enfoques metaheurísticos podrían reducir significativamente los tiempos de cálculo en modelos más complejos, sin sacrificar la precisión de los resultados.

En resumen, el modelo presentado en este trabajo constituye una base sólida para el análisis y optimización de políticas de mantenimiento, pero existen múltiples áreas de mejora que pueden expandir sus capacidades y adaptarlo mejor a escenarios más complejos y realistas.

Bibliografía

- [1] Suzan Alaswad and Yisha Xiang. A review on condition-based maintenance optimization models for stochastically deteriorating system. *Reliability Engineering and System Safety*, 157:54–63, 1 2017. [\(document\)](#), [4.3.1](#), [4.1](#), [4.2](#), [5](#)
- [2] Bram de Jonge and Philip A. Scarf. A review on maintenance optimization, 9 2020. [1](#)
- [3] Mahmood Shafiee and Stefanka Chukova. Maintenance models in warranty: A literature review. *European Journal of Operational Research*, 229:561–572, 9 2013. [1](#)
- [4] Wenyu Zhang, Jie Gan, Shuguang He, Ting Li, and Zhen He. An integrated framework of preventive maintenance and task scheduling for repairable multi-unit systems. *Reliability Engineering and System Safety*, 247, 7 2024. [1](#)
- [5] Farshid Nasrfard, Mohammad Mohammadi, and Mohammad Rastegar. Probabilistic optimization of preventive maintenance inspection rates by considering correlations among maintenance costs, duration, and states transition probabilities. *Computers and Industrial Engineering*, 173, 11 2022. [1](#), [5](#)
- [6] Andres Escobar, Mauricio Holguin, and Gustavo Betancourt. Maintenance models in warranty: A literature review. *Scientia et Technica*, 13:115–120, 5 2007. [1](#)
- [7] A Crespo. *The Maintenance Management Framework: Models and Methods for Complex Systems Maintenance*. Springer Series in Reliability Engineering. Springer London, 2007. [4.1](#), [4.1.2](#), [4.2.1](#), [4.2.2](#)
- [8] J. Moubray. *Reliability-centered Maintenance*. G - Reference, Information and Interdisciplinary Subjects Series. Industrial Press, 2001. [4.1.1](#), [4.2.2](#)
- [9] David Saint-Voirin and Noureddine Zerhouni. Cooperative systems modeling, example of a cooperative e-maintenance system. In *The 2nd International Conference on Distributed Frameworks for Multimedia Applications*, pages 1–8. IEEE, 2006. [4.1.2](#)
- [10] Tiago Zonta, Cristiano André Da Costa, Rodrigo da Rosa Righi, Miromar Jose de Lima, Eduardo Silveira da Trindade, and Guann Pyng Li. Predictive maintenance in the industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150:106889, 2020. [4.2.3](#)
- [11] V. Narayan. *Effective Maintenance Management: Risk and Reliability Strategies for Optimizing Performance*. Industrial Press, 2004. [4.3](#)
- [12] P Lyonnet. *Maintenance Planning: Methods and Mathematic*. Springer Netherlands, 2013. [4.3.2](#)
- [13] Byron A Ellis. Condition-based maintenance, 2008. [4.3.2](#)
- [14] Ruhul Sarker and Amanul Haque. Optimization of maintenance and spare provisioning policy using simulation. *Applied Mathematical Modelling*, 24(10):751–760, 2000. [4.4](#)
- [15] Subhash Mathew. Optimal inspection frequency: A tool for maintenance planning/forecasting. *International Journal of Quality and Reliability Management*, 21:763–771, 2004. [4.4](#), [5](#)
- [16] R. Ramakumar. *Engineering Reliability: Fundamentals and Applications*. And Its Applications. Prentice Hall, 1993. [4.4](#)

- [17] H.P. Bloch and F.K. Geitner. *Machinery Failure Analysis and Troubleshooting: Practical Machinery Management for Process Plants*. Practical Machinery Management for Process Plants. Elsevier Science, 2012. [4.4](#)
- [18] R.B. Abernethy. *The New Weibull Handbook: Reliability & Statistical Analysis for Predicting Life, Safety, Risk, Support Costs, Failures, and Forecasting Warranty Claims, Substantiation and Accelerated Testing, Using Weibull, Log Normal, Crow-AMSAA, Probit, and Kaplan-Meier Models*. R.B. Abernethy, 2006. [4.5](#), [4.5.1](#), [4.5.3](#)
- [19] J.I. McCool. *Using the Weibull Distribution: Reliability, Modeling, and Inference*. Wiley Series in Probability and Statistics. Wiley, 2012. [4.5.1](#), [4.5.3](#)
- [20] D.J. Smith. *Reliability, Maintainability and Risk: Practical Methods for Engineers*. Elsevier, 2011. [4.5.2](#), [4.5.3](#)
- [21] C.Z. Mooney. *Monte Carlo Simulation*. Number n.º 116 in Monte Carlo Simulation. SAGE Publications, 1997. [4.6](#)
- [22] E. Zio. *The Monte Carlo Simulation Method for System Reliability and Risk Analysis*. Springer Series in Reliability Engineering. Springer London, 2013. [4.6.1](#), [4.6.2](#)
- [23] M. Modarres, M. Kaminskiy, and V. Krivtsov. *Reliability Engineering and Risk Analysis: A Practical Guide*. Taylor & Francis, 2016. [4.6.2](#)
- [24] W.D. Kelton, R.P. Sadowski, and D.T. Sturrock. *Simulation with Arena*. McGraw-Hill series in industrial engineering and management science. McGraw-Hill Higher Education, 2007. [4.6.2](#)
- [25] J. Banks. *Discrete-event System Simulation*. Prentice Hall, 2010. [4.6.2](#)
- [26] Fatima Zohra Berrabah, Chahira Belkacemic, and Leila Zemmouchi-Ghomari. Essential and new maintenance kpis explained. *International Journal of Education and Management Engineering*, 12(6):11–20, 2022. [4.7](#), [4.7.1.1](#), [4.7.1.2](#)
- [27] Horst Meier, Henning Lagemann, Friedrich Morlock, and Christian Rathmann. Key performance indicators for assessing the planning and delivery of industrial services. *Procedia CIRP*, 11:99–104, 2013. 2nd International Through-life Engineering Services Conference. [4.7](#)
- [28] D. Parmenter. *Key Performance Indicators: Developing, Implementing, and Using Winning KPIs*. Wiley, 2019. [4.7.1](#)
- [29] Elena Gonzalez et. al. Key performance indicators for wind farm operation and maintenance. *Energy Procedia*, 137:559–570, 2017. [4.7.1.3](#)
- [30] M. Modarres. *Risk Analysis in Engineering: Techniques, Tools, and Trends*. Manufacturing and industrial engineering. Taylor & Francis, 2016. [4.8](#)
- [31] M. Rausand and A. Hoyland. *System Reliability Theory: Models, Statistical Methods, and Applications*. Wiley Series in Probability and Statistics - Applied Probability and Statistics Section. Wiley, 2011. [4.8](#)
- [32] Louis Anthony Cox Jr. *Risk Analysis of Complex and Uncertain Systems*. Springer, New York, 2009. [4.8](#)
- [33] Arnljot Høyland and Marvin Rausand. *System Reliability Theory: Models, Statistical Methods, and Applications*. John Wiley & Sons, 1st edition, 1994. [4.8](#)
- [34] Tyrrell Rockafellar and Stanislav Uryasev. Conditional value at risk for general loss distributions. *Journal of Banking & Finance*, 26(7):1443–1471, 2002. [4.8.1](#)

- [35] *Conditional value at risk: optimization algorithms and applications*, 2002. 4.8.1
- [36] K. Ellis, W. Ferrell, and J. Knapp, editors. *Reliability Assessment of Scenarios for CVaR Minimization in Two-Stage Stochastic Programs*. Institute of Industrial and Systems Engineers (IISE), 2022. 4.8.1
- [37] Chia-Lin Chang, Juan Ángel Jiménez-Martín, Esfandiar Maasoumi, and Teodosio Pérez-Amaral. A stochastic dominance approach to financial risk management strategies. *Journal of Econometrics*, 187(2):472–485, 2015. *Econometric Analysis of Financial Derivatives*. 4.8.2
- [38] A. Saltelli, M. Ratto, T. Andres, F. Campolongo, J. Cariboni, D. Gatelli, M. Saisana, and S. Tarantola. *Global Sensitivity Analysis: The Primer*. Wiley, 2008. 4.8.3
- [39] N Yang. Inspection frequency optimization for aircraft structures based on reliability analysis. *Journal of Aircraft*, 12(5), 1975. 5
- [40] Hesham Alfares. A simulation model for determining inspection frequency. *Computer & Industrial Engineering*, 36:685–696, 1999. 5
- [41] Vladimir Babishin and Sharareh Taghipour. Optimal maintenance policy for multicomponent systems with periodic and opportunistic inspections and preventive replacements. *Applied Mathematical Modelling*, 40, 2016. 5
- [42] Mahmood Shafiee and John Dalsgaard. Maintenance optimization and inspection planning of wind energy assets: Models, methods and strategies. *Reliability Engineering and System Safety*, 2019. 5
- [43] Rui Assis and Pedro Carmona. A dynamic methodology for setting up inspection time intervals in conditional preventive maintenance. *Applied Sciences*, 2021. 5
- [44] Zhiying Wu Aibo Zhang, Xingheng Liu and Min Xie. A novel modeling framework for a degrading system subject to hierarchical inspection and maintenance policy. *Applied Mathematical Modelling*, 2023. 5
- [45] Haidong Yang Biyu Liu, Jie Pang and Yilin Zhao. Optimal condition-based maintenance policy for leased equipment considering hybrid preventive maintenance and periodic inspection. *Reliability Engineering and System Safety*, 2024. 5
- [46] Nima Gorjian, Lin Ma, Murthy Mittinty, Prasad Yarlagadda, and Yong Sun. A review on degradation models in reliability analysis. In Dimitris Kiritsis, Christos Emmanouilidis, Andy Koronios, and Joseph Mathew, editors, *Engineering Asset Lifecycle Management*, pages 369–384, London, 2010. Springer London. 5
- [47] F. Hartoyo, G.P. Irianti, J.F. Fatriansyah, H. Ovelia, I.A. Mas’ud, F.R. Digita, A. Fauzi, and M. Anis. Weibull distribution optimization for piping risk calculation due to uniform corrosion using monte carlo method. *Materials Today: Proceedings*, 80(Part 2):1650–1655, 2023. 7
- [48] W. Hu, Z. Yang, C. Chen, Y. Wu, and Q. Xie. A weibull-based recurrent regression model for repairable systems considering double effects of operation and maintenance: A case study of machine tools. *Reliability Engineering and System Safety*, 213:107669, 2021. 7
- [49] S. Bracke. Preventive maintenance planning based on weibull distribution models: The impact of the random scatter behaviour of the threshold parameter. *IFAC-PapersOnLine*, 53(3):161–166, 2020. 7
- [50] C. D. Lai, D. N. Murthy, and M. Xie. Weibull distributions and their applications. In H. Pham, editor, *Springer Handbook of Engineering Statistics*, pages 63–78. Springer London, 2006. 7.7

- [51] J. M. Barraza-Contreras, M. R. Pina-Monarez, and R. C. Torres-Villasenor. Reliability by using weibull distribution based on vibration fatigue damage. *Applied Sciences*, 13(18):10291, 2023. [7.7](#)

