



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
Energía – Sistemas Energéticos

Desarrollo de modelos probabilísticos para la estimación de mecanismos de daño en los
álabes de turbinas de vapor

TESIS
QUE PARA OPTAR POR EL GRADO DE:
DOCTOR EN INGENIERÍA

PRESENTA:
David Alejandro Quintanar Gago

TUTOR PRINCIPAL

Dra. Pamela Fran Nelson Edelstein (Facultad de Ingeniería-UNAM)

COMITÉ TUTOR

Dr. Juan Luis François Lacouture (Facultad de Ingeniería-UNAM)

Dra. Cecilia Martín del Campo Márquez (Facultad de Ingeniería-UNAM)

Dra. Ángeles del Consuelo Díaz Sánchez (Instituto Nacional de Investigaciones Nucleares)

Ciudad Universitaria, CD. MX, ENERO DE 2021



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

JURADO ASIGNADO:

Presidente: Dr. Juan Luis François Lacouture
Secretario: Dra. Cecilia Martín del Campo Márquez
1 er. Vocal: Dra. Pamela Fran Nelson Edelstein
2 do. Vocal: Dra. Ángeles del Consuelo Díaz Sánchez
3 er. Vocal: Dr. Carlos Chávez Mercado

Ciudad Universitaria, CD. MX

TUTOR DE TESIS:

Dra. Pamela Fran Nelson Edelstein

FIRMA

*A mi abuela Mami, que es la estrella de este sistema solar
al que orgullosamente pertenezco, mi Familia*

Una mariposa bate sus alas y del otro lado del planeta se forma un huracán. Afortunadamente, es sólo un ejemplo de que cada evento genera consecuencias, a veces pequeñas, imperceptibles, o gigantes, inimaginables. A lo largo de cuatro años y medio, quiero agradecer a todos aquellos cuyas consecuencias de sus acciones, conscientes o no, se han acumulado, contribuyendo positivamente a que yo pudiera culminar esta tesis...

A mi familia, que siempre me ha apoyado desde que tengo uso de razón. Todo lo que hago, es por ellos. Son mi principal fuente de motivación e inspiración. Ellos, y sólo ellos, saben el verdadero esfuerzo y costo de este trabajo. Gracias por estar para mí

A mi esposa Saray, mi rosa, que me demostró que lo esencial sólo se ve con el corazón, que a pesar de la distancia, se ha mantenido a mi lado, transfiriéndome todo lo bueno que en ella existe

A mis amigos Yeney y Ronald que tanta beca me han dado en su casa, Oreste, Erick, Ariel y Néstor, gracias a todos por estar cuando los necesito, por los momentos que hemos compartido

A mi tutora, la Dra. Pamela F. Nelson, por los cientos de horas de dedicación que me ha regalado desde el comienzo de este trabajo, por creer en mí desde el principio

A los miembros de mi comité tutor, Ángeles, François y Cecilia, por su apoyo

A Ricardo y Manuel, que arrojaron luz y esperanza cuando más la necesitaba

Al Consejo Nacional de Ciencia y Tecnología de México (CONACYT), por patrocinar esta investigación.

Resumen

Las turbinas de vapor son sistemas claves de conversión de energía en el sector de la producción eléctrica. Dentro de las mismas, los álabes constituyen una población numerosa de elementos semejantes, los cuales están sometidos a complejas y agresivas condiciones ambientales que varían de acuerdo con su ubicación, generando diversos mecanismos de daño (MD) que provocan los fallos. Tales fallos requieren períodos de mantenimiento prolongados y millones de dólares en reparaciones y en costos de reemplazo de energía durante el período en que la producción se interrumpe. La experiencia indica que los MD que afectan la confiabilidad de los componentes son procesos dependientes, en los que la presencia de unos influye incrementando la probabilidad de desarrollo de otros. Los análisis de confiabilidad no consideran explícitamente los MD o en ocasiones dichas dependencias son simplificadas a eventos independientes. El proceso de identificación de los MD es clave para la prosecución de las actividades de mantenimiento y la toma de decisiones, pero existe la posibilidad de una mala identificación u omisión, repercutiendo en la confiabilidad de la turbina.

Ante estas problemáticas se presentan dos nuevos modelos probabilísticos complementarios que contemplan las dependencias existentes entre los MD que inducen los fallos en los componentes. Los modelos desarrollados son aplicados a los álabes rotatorios de una turbina de vapor nuclear para demostrar las nuevas capacidades de análisis, aunque pueden ser extrapolados a otros tipos de turbinas.

El primer modelo es una red bayesiana estática que funge como herramienta analítica para la identificación y ubicación de los MD en los álabes. En el modelo se consideran las dependencias probabilísticas condicionales entre los MD, las filas y partes de los álabes susceptibles y los modos de fallo que se producen. En el segundo modelo (dinámico), los MD y sus influencias son dependientes del tiempo, permitiendo el desarrollo de nuevos modelos de mantenimiento enfocados en la reparación (eliminación) de cada MD por separado. Las acciones de mantenimiento modifican las influencias entre los MD, provocando cambios en la función de riesgo de la curva de confiabilidad calculada para el componente en cuestión, por lo que es un nuevo tipo de mantenimiento imperfecto.

El juicio de expertos es utilizado para cuantificar ambos modelos. Con este fin, una versión Extendida del *Recursive Noisy OR* (ERNOR) es desarrollada. En su versión estática, se calculan probabilidades puntuales sinérgicas para evaluar combinaciones desconocidas de las tablas de probabilidad condicional a partir de combinaciones más fáciles de encuestar a expertos, y es usada en el primer modelo. Su versión dinámica genera probabilidades conjuntas continuas a partir de las funciones de distribución acumuladas de las causas, útil en el segundo modelo.

La consideración de los MD en los modelos desarrollados proporciona una granularidad que ofrece al analista un mejor entendimiento de los principales mecanismos contribuyentes al fallo, determinar las ubicaciones más propensas, modelar mantenimientos enfocados en MD específicos y estimar su evolución temporal.

Abstract

Steam turbines are key power conversion units for electric power generation. Large steam turbines contain hundreds of blades subjected to complex and hostile environmental conditions that vary according the location, generating a set of damage mechanisms (DM) that ultimately cause blade failures. Such failures require extended maintenance periods and potentially, the replacement of costly internal components that can cause millions of dollars in overall losses and in replacement power costs for the time period of business interruption. Operational experience indicates that DMs affecting component reliability are dependent events, thus, the probability of one mechanism producing a failure can be affected by the presence of other mechanisms. Reliability analyses do not explicitly consider the DMs or often the dependencies are simplified. Correct identification of the DMs is crucial for maintenance decision making; however, turbine reliability and performance can be compromised due to unnoticed or misidentified DMs in blades.

Given the aforementioned, two new probabilistic models that account for the DMs that affect component reliability and their dependencies, are developed. To demonstrate the analysis capabilities of the models, they are applied to nuclear steam turbine rotating blade common DMs, however, they can be extended to other turbine technologies.

The first model is a static Bayesian network, a tool that provides a framework to perform different analyses to assist in the identification and location of the contributing DMs to failures. It considers the conditional probabilistic dependence among DMs, failure modes, and their susceptible locations in rotating blades. The second model is dynamic, thus, the DMs and their dependencies are time dependent, allowing the development of new maintenance models focused on each individual DM. Maintenance actions modify the influences among DMs, resulting in complex hazard functions that reshape the computed reliability curve for the component, thus resulting in a new kind of imperfect maintenance modeling.

Expert judgement is used in both model quantifications. With this purpose, the Extended Recursive Noisy OR model is developed. In its static version, used in the first model, the results are punctual synergic joint probabilities from a set of causes achieving an effect,

useful to populate large conditional probability tables. The dynamic version handles cumulative distribution functions, representing the joint probability of time dependent causes, useful in the second model.

The consideration of the DMs and their dependencies in the developed models provides the analyst with a refined level of granularity to better understand the mechanisms that contribute to blade failures, identify susceptible locations, to model imperfect maintenance tasks and predict their evolution to better inform maintenance activities.

Contenido

Abreviaturas	XIV
Introducción.....	1
Problema científico	3
Objeto de estudio.....	3
Hipótesis.....	3
Objetivo General.....	4
Objetivos específicos.....	4
Principales Contribuciones	4
Estructura de la tesis	6
Capítulo I: Las turbinas de vapor y los mecanismos de daño en los álabes	8
1.1. Comportamiento de los fallos y mecanismos de daño en álabes.	11
1.2. Mecanismos presentes en las turbinas de centrales nucleares.....	17
1.2.1. Impacto por gotas	17
1.2.2. Fatiga mecánica simple	18
1.2.3. Corrosión de la superficie por picaduras.....	19
1.2.4. Agrietamiento asistido por corrosión bajo tensión.....	20
1.2.5. Fatiga asistida por corrosión o corrosión fatiga.....	21
1.2.6. Fricción.....	22
1.3. Técnicas para identificar los MD en turbinas	23
1.4. Resumen y conclusiones parciales: mecanismos de daño y turbinas	26
Capítulo II: Redes Bayesianas	29
2.1. Fundamentos de las Redes Bayesianas	30
2.2. Métodos de cuantificación de las redes bayesianas.....	34
2.3. Resumen y conclusiones parciales: redes bayesianas y cuantificación	39
Capítulo III: Recursive Noisy OR Extendido.....	41
3.1. El modelo Recursive Noisy OR.....	42
3.2. RNOR Dinámico	44
3.3. Análisis de reducción del DRNOR.....	47
3.4. RNOR Extendido	50
3.5. Dedución del ERNOR y su expresión general	51

3.6. Análisis del ERNOR.....	56
3.7. Ejemplo cuantitativo.....	59
3.8. Resumen y conclusiones parciales: Recursive Noisy OR Extendido.....	63
Capítulo IV: Evaluación de los mecanismos de daño de los álabes de la turbina de vapor usando una red bayesiana	65
4.1. Metodología general	66
4.2. Análisis de sistema	66
4.2.1. Interacción entre los mecanismos de daño	67
4.2.2. Modos de fallo.....	67
4.2.3. Simetrías del sistema	69
4.3. Determinación de la RB.....	70
4.4. Cuantificación de la RB	73
4.4.1. Características deseadas para el cálculo de las TPC del modelo estático ..	73
4.4.2. Pasos para calcular las TPC del modelo	75
4.4.3. Datos.....	83
4.5. Validación	84
4.6. Uso del modelo y resultados cuantitativos.....	88
4.7. Contribuciones del modelo de RB para evaluar los MD en turbinas.....	93
4.7.1. Contribuciones para el campo de mantenimiento en turbinas.....	93
4.7.2. Contribuciones para los métodos de cómputo de las TPC	94
4.7.3. Extensibilidad del modelo.....	95
4.8. Resumen y conclusiones parciales: modelo de RB para una turbina de vapor ..	96
Capítulo V: Evaluación de las dependencias dinámicas de los mecanismos de daño..	98
5.1. Sistemas y componentes sujetos a mantenimiento	101
5.2. Teoría del modelo para mecanismos de daño dependientes y dinámicos	104
5.2.1. Conceptos básicos.....	105
5.2.2. Condiciones del modelo.....	107
5.3. Estudio de casos	112
5.3.1. Variación del momento de mantenimiento de los potenciadores	112
5.3.2. Mantenimiento de subconjuntos de potenciadores	114
5.3.3. Variación de parámetros en el leak.....	115

5.4. Ejemplo del modelo para varios potenciadores y mecanismos dependientes..	116
5.5. Aplicación a un componente.....	117
5.6. Resultados del modelo	120
5.7. Resumen y conclusiones parciales: modelo para mecanismos de daño dependientes y dinámicos	123
Resumen y Conclusiones Generales	126
Referencias	130
Anexo A: Encuesta de datos para evaluar el impacto de los mecanismos de daño en los álabes de turbinas de vapor	142
Anexo B: Cálculo de las tablas de probabilidad condicional a partir de la encuesta ...	152

Lista de Figuras

Figura 1: Distribución de fallos de álabes por fila, comparación entre turbinas de baja presión nucleares y fósiles.	13
Figura 2: Influencias dinámicas de las causas	44
Figura 3: Comportamiento dinámico de las probabilidades conjuntas según los modelos DN-OR, DRNOR y ERNOR.....	61
Figura 4: Metodología para desarrollar el modelo de RB.....	66
Figura 5: (A) Esquema simplificado de una sección de baja presión mostrando las filas de álabes. (B) Discretización utilizada en este estudio de un álabe (derecha).	70
Figura 6: Red bayesiana que describe los modos de fallo y mecanismos de daño en una turbina de vapor nuclear de baja presión.	71
Figura 7: Cálculo de la matriz <i>leak</i> para un MD. Pasos del 1 al 4	78
Figura 8: Cálculo de las TPC. Pasos del 5 al 8	82
Figura 9: Efecto de la variación de las probabilidades <i>prior</i> y TPC de los nodos padre. Análisis para las raíces de la fila L-0.	87
Figura 10: Efecto de las probabilidades de influencia en los nodos SCC_MD, Fatiga_MD y CF_MD para combinaciones seleccionadas de padres en las raíces de la fila L-0.	88
Figura 11: Estimación de las ubicaciones más propensas a sufrir de agrietamiento por CF influenciado por picaduras. Vista de nodos en monitores creada en GeNie.	89
Figura 12: (A) Mecanismos de daño que provocan Ag/Fr_MF en las raíces con los demás MD ausentes. (B) <i>Ídem</i> con Fricc_MD presente.....	91
Figura 13: Esquema de conexiones de los MD considerando dependencias.	106
Figura 14: Señal de mantenimiento $M_{Y_l}(t = T)$	108
Figura 15: Mantenimiento $M_{Y_l}(t = 10)$	109
Figura 16: Señal de mantenimiento $M_{Y_l-x_5}(t = T)$	111
Figura 17: Mantenimiento $M_{Y_l-x_5}(t = 10)$	112
Figura 18: Influencia sobre $F_{Y_l}(t)$ de $M_{Y_l-x_{1,2,3,4,5}}(t)$ en diferentes momentos.	113

Figura 19: Influencia sobre $F_{Y_l}(t)$ del mantenimiento en subconjuntos de potenciadores.
 114

Figura 20: Sensibilidad del *leak* $F_{y_l}(t)$ para diferentes valores del factor de escala y
 forma. 115

Figura 21: Estructura general con varios MD potenciadores y dependientes. 117

Figura 22: Modelo general para el álabe..... 118

Figura 23: Distribuciones acumuladas para los MD y compuerta OR tope considerando
 independencias. 121

Figura 24: Distribuciones acumuladas para los MD y compuerta OR tope considerando
 las dependencias. 122

Figura 25: Comparación entre las compuertas OR tope, asumiendo independencia y
 dependencia entre los MD. 123

Figura 26: Modelo simplificado de la red bayesiana..... 142

Figura 27: (A) Sección transversal de una turbina de baja presión, mostrando las filas
 de álabes. (B) Partes o porciones de un álabe. 143

Lista de tablas

Tabla 1: Estadística de los fallos de los álabes en las tres secciones de las turbinas (fósil y nuclear).....	14
Tabla 2: Lugares donde se producen fallos de álabes en turbinas (fósil y nuclear).	15
Tabla 3: Consecuencias económicas de los fallos de los álabes.....	16
Tabla 4: Comparación entre los modelos estáticos N-OR, RNOR y ERNOR.	60
Tabla 5: Parámetros de la distribución Weibull de las causas.	61
Tabla 6: Descripción de los nodos en la RB.....	72
Tabla 7: Representación del nodo Alabe_PP y sus restricciones	76
Tabla 8: Datos de entrada para el modelo de RB	85
Tabla 9: Conjuntos de evidencia.	90
Tabla 10: Parámetros para distribución de Weibull de los MD.....	120

Abreviaturas

Siglas	Significado	Meaning
AF	Árbol de fallos	Failure tree
AND	Compuerta lógica tipo Y determinista	Deterministic AND logic gate
AR	Axioma de reducción	Reduction axiom
CEV	Conjunto de evidencias	Evidence set
CF	Corrosión Fatiga	Corrosion Fatigue
CU	Causa unitaria	Singleton
DN-OR	Compuerta lógica dependiente del tiempo del tipo O con "ruido"	Dynamic Noisy OR
DRNOR	Compuerta lógica recursiva y dependiente del tiempo del tipo O con "ruido"	Dynamic Recursive Noisy OR
EB	Evento básico	Basic event
EPRI	Instituto de Investigación de Energía Eléctrica	Electric Power Research Institute
ERNOR	Compuerta lógica recursiva extendida del tipo O con "ruido"	Extended Recursive Noisy OR
FDA	Función de distribución acumulada	Cumulative distribution function, also CDF
FDP	Función de densidad de probabilidad	Probabilistic density function, also PDF
FL	Factor leak	Leak factor
FP	Función potenciadora	Enhancer function
GeNie	Programa de cómputo para redes bayesianas	Bayesian Network software
L-"N"	Del inglés <i>last minus</i> (el último menos)-"N". Especifica la fila de álabes una turbina de baja presión	last minus... "N". It is the turbine blade row identification
MD	Mecanismo de daño	Damage mechanism
MF	Modo de fallo	Failure mode
MS	Matriz de susceptibilidad	Susceptibility Matrix
N-AND	Compuerta lógica tipo Y con "ruido"	Noisy AND logic gate
N-OR	Compuerta lógica tipo O con "ruido"	Noisy OR logic gate
OR	Compuerta lógica tipo O determinista	Deterministic OR logic gate
PI	Probabilidad de influencia	Influence probability
PIC	Probabilidad de influencia conjunta	Joint influence probability
PII	Probabilidad de influencia individual	Independent influence probability
RB	Red bayesiana	Bayesian network
RBD	Red bayesiana dinámica	Dynamic bayesian network
RNOR	Compuerta lógica recursiva del tipo O con "ruido"	Recursive Noisy OR

Abreviaturas (continuación)

Siglas	Significado	Meaning
SCC	Agrietamiento por corrosión bajo tensión. Se usa su abreviatura del inglés	Stress corrosion cracking
st	Salto o paso temporal	Temporal step
TPC	Tabla de probabilidad condicional	Conditional probability table
TR	Transformación	Transformation
VA	Variable aleatoria	Random variable
VBA	Visual Basic para Aplicaciones	Visual Basic for Applications
ZTF	Zona de transición de fases	Phase transition zone

Introducción

Las grandes turbinas de vapor son unidades clave en la producción de energía eléctrica y otros servicios donde las turbinas proporcionan energía mecánica. La confiabilidad de las grandes turbinas de vapor depende de que se apliquen las correctas actividades de mantenimiento y representa un elemento de inversión significativa y continua para los propietarios de centrales eléctricas. En la mayoría de los casos, las acciones de mantenimiento llevadas a cabo en las turbinas, dada su complejidad, forman parte de las tareas críticas en las paradas programadas de las centrales.

Las turbinas principales de las centrales eléctricas contienen muchos componentes sometidos a complejas combinaciones de tensiones mecánicas y condiciones ambientales adversas, que inducen una serie de mecanismos de daño que afectan la eficiencia y confiabilidad de los componentes y, por lo tanto, de todo el sistema. Mecanismo de daño (MD) es un término general que se refiere a cualquier proceso que actúa en los materiales, provocando eventualmente el fallo del componente que conforman a través de la degradación o desgaste de las propiedades del material. Los mecanismos incluyen corrosión, agrietamiento, erosión, etc., y son los que contribuyen a la ocurrencia del fallo.

Un elemento clave dentro de las turbinas son los álabes, componentes que se encargan directamente de generar momento en interacción con las boquillas fijas y el fluido de trabajo. Estos elementos son de gran interés desde el punto de vista de la confiabilidad por las consecuencias de sus fallos, como la indisponibilidad total de la planta. Un solo álabe fallado puede hacer que la turbina quede indisponible, representando un arreglo en serie con cientos de componentes similares. Las consecuencias directas comunes son la destrucción de otros componentes dentro de la trayectoria del vapor, como otros álabes giratorios o fijos. Las consecuencias suelen ser más significativas en los fallos de los álabes más grandes y masivos de las últimas filas de las turbinas de baja presión, provocando daños en las tuberías del condensador, pandeo del rotor de la turbina por desbalance de masa, lo cual afecta las estructuras de soporte de los rodamientos por

cargas oscilatorias, aumentando la probabilidad de incendios del aceite lubricante e incluso en el generador. Desde la perspectiva del propietario, tales fallos requieren períodos de mantenimiento prolongados y, potencialmente, el reemplazo de componentes internos costosos que pueden causar millones de dólares en pérdidas generales y costos de reemplazo de energía no producida durante el período de tiempo de interrupción.

Los MD no necesariamente actúan de forma independiente, y dentro de un solo elemento estructural pueden actuar simultáneamente, afectando uno el comportamiento de otros. Por ejemplo, la presencia del mecanismo A (p. ej., Picaduras) puede acelerar el inicio y/o propagación del mecanismo B (p. ej., Agrietamiento asistido por corrosión bajo tensión), por lo que la probabilidad de que el elemento sufra un fallo por el mecanismo B dependerá también de la presencia del mecanismo A y su influencia sobre B. Siguiendo esta línea de pensamiento es evidente que cuando se tienen n mecanismos coexistiendo para provocar el fallo del componente, se obtiene una compleja red de interacciones que pueden ser expresadas mediante probabilidades condicionales. En los álabes de turbinas, los estudios indican que existe también una fuerte dependencia de los MD y sus interacciones con la ubicación del álabe dentro de la misma, debido a variaciones en las condiciones de operación de cada fila y parte del álabe en cuestión.

A pesar de lo antedicho, una limitación es que la consideración de los MD en los análisis de confiabilidad es compleja debido a la gran variedad de modelos geométricos, materiales y condiciones de trabajo para cada fila y parte del álabe dentro de una turbina. Por lo tanto, es frecuente que los MD no aparezcan en estos análisis de forma explícita, como sucede en los árboles de fallo (AF), o, cuando son considerados, sus dependencias son obviadas, considerándolos como eventos independientes, lo que constituye un enfoque simplificado que dificulta el entendimiento de las principales causas del fallo. Es por esto que los estudios tomen principalmente dos enfoques respecto al tratamiento del álabe: el de tratarlos como un super componente, o sesgar el análisis a condiciones muy particulares de operación, por lo que los resultados y métodos son igualmente específicos y de limitada extrapolación.

Dado que los álabes rotatorios se encuentran en la trayectoria del vapor, determinar exactamente si estos están siendo afectados por uno o más MD se torna una tarea compleja. La tarea de identificar los MD que producen los fallos requiere considerable tiempo y esfuerzo, especialmente cuando existen numerosos componentes a inspeccionar, como en el caso de los álabes de las turbinas. Esto se torna aún más difícil si el trabajo de mantenimiento e inspección de la turbina se realiza bajo restricciones de calendario o si se limita a realizarse a través de puertos de inspección con herramientas de inspección remota. Por lo tanto, la confiabilidad y el rendimiento de la turbina pueden verse comprometidos debido a MD desapercibidos o mal identificados en los álabes, representando pérdidas económicas para los propietarios.

Problema científico

Por lo tanto, se hace necesaria la elaboración de modelos probabilísticos que consideren las dependencias de los MD que afectan a los componentes como los álabes de turbinas de vapor, y de éstos con su ubicación dentro del sistema debido a las diferentes condiciones de operación a las cuales son sometidos; esto, con el ánimo de facilitar la identificación de los mecanismos que inducen fallos y su evolución en el tiempo para lograr un mejor entendimiento de los procesos que afectan la confiabilidad, proporcionando información para la toma de decisiones en las subsecuentes tareas de mantenimiento.

Objeto de estudio

Mecanismos de daño y sus dependencias probabilísticas que afectan la confiabilidad de los componentes, específicamente de los álabes rotatorios en turbinas de vapor.

Hipótesis

Si se consideran explícitamente los MD y sus dependencias probabilísticas en los modelos de confiabilidad de los álabes rotatorios de una turbina de vapor, se obtendrá una granularidad que permite la identificación de las causas de los fallos, las ubicaciones más susceptibles y el modelado de actividades de mantenimiento imperfecto enfocados en cada MD por separado.

Objetivo General

Desarrollar nuevos modelos para el análisis de confiabilidad de componentes que consideren las dependencias existentes, en términos de probabilidades condicionales, entre los MD que afectan la probabilidad de fallo.

Objetivos específicos

1. Identificar los MD que afectan los álabes, así como las dependencias existentes entre ellos y su relación con la ubicación dentro de una turbina.
2. Determinar la factibilidad de las redes bayesianas (RB) y de los métodos de cuantificación de sus tablas de probabilidad condicional (TPC), para la confección de modelos que tengan en cuenta las relaciones existentes entre los MD que inducen los fallos en los componentes.
3. Desarrollar un método de cuantificación que considere los efectos sinérgicos de las combinaciones de los MD a partir del conocimiento de expertos, así como confeccionar la encuesta para solicitar los valores de entrada a los modelos que se desarrollan posteriormente.
4. Desarrollar un modelo estático basado en RB que considere las dependencias probabilísticas entre los MD, su relación con las diferentes partes del álabe y filas de una turbina de baja presión y los modos de fallo (MF) que estos producen, con el fin de proporcionar una herramienta de identificación de los MD más importantes en los fallos y la susceptibilidad de las ubicaciones dentro de la turbina.
5. Desarrollar un modelo para evaluar las dependencias de los MD de forma dinámica, considerando tareas de mantenimiento enfocadas en cada MD de forma individual.

Principales Contribuciones

Se desarrolla una versión Extendida del *Recursive Noisy OR* (ERNOR) para el cálculo automático de probabilidades conjuntas de causas (en general, señales), a partir del juicio de expertos. En el ERNOR se resuelve el problema de la asimetría del original RNOR cuando la cantidad de causas excede tres. En el proceso se expone el origen de la asimetría del RNOR y sus consecuencias. El ERNOR, en su versión estática, permite

el cálculo de probabilidades puntuales sinérgicas de las influencias de cualquier cantidad de causas, contribuyendo al estado del arte de los métodos automáticos para generar TPC no restringidos por el principio de independencia de influencia causal (ICI). La extensión incluye una versión dinámica, que genera distribuciones acumuladas de las probabilidades conjuntas sinérgicas de las causas, basadas en el nivel de presencia de estas últimas. En otras palabras, se pasa de un modelo de cálculo de probabilidades puntuales (ERNOR estático) a uno de probabilidades continuas (ERNOR dinámico). La consideración del tiempo en este último permite que el ERNOR pueda ser contemplado como una nueva compuerta lógica en programas de confiabilidad, donde las señales de entrada pueden ser eventos básicos con distribuciones probabilísticas acumuladas (DPA) asociadas, cuyo efecto se refuerza.

Se desarrolla un modelo estático basado en RB que considera la dependencia probabilística condicional entre los MD que afectan la confiabilidad de los álabes mediante diversos MF, así como la susceptibilidad de las diferentes ubicaciones (filas y partes de los álabes) a sufrir de los MD. Este se implementa para una turbina de una central nuclear pero su metodología puede extenderse a toda clase de turbinas de varias filas de álabes. El modelo estático de RB contribuye principalmente en dos áreas: mantenimiento y métodos de cuantificación de TPC.

En cuanto al mantenimiento, el modelo es una herramienta analítica de alta granularidad que permite determinar los mecanismos responsables de los fallos y las ubicaciones propensas, así como análisis de sensibilidad basados en conjeturas que son introducidas en los nodos como evidencia para luego ser propagada. Los resultados proporcionan información detallada para la toma de decisiones en el proceso de mantenimiento con el fin de ahorrar recursos y aumentar la disponibilidad. El método de cálculo de las TPC específico para este modelo usa el ERNOR combinado con un procedimiento de clasificación de la susceptibilidad de las ubicaciones de los álabes a los MD. Por esta razón, las TPC para los MD poseen múltiples *leaks*, contrastando con los procedimientos de cuantificación consultados en la bibliografía que poseen un solo valor *leak* por tabla. El método genera grandes tablas a partir de pocos parámetros de entrada, por ejemplo,

con 20 valores encuestados con sólo 9 preguntas, se genera una TPC binaria con 288 combinaciones.

El segundo modelo desarrollado es dinámico, donde se tienen en cuenta explícitamente y en función del tiempo, los MD y sus interacciones que contribuyen al fallo de los componentes. En este sentido unos MD son potenciadores e incrementan la probabilidad de que otros MD dependientes causen el fallo del componente. En el modelo se formaliza la descomposición de un elemento en sus MD mediante el uso del ERNOR dinámico y las probabilidades de influencia encuestadas a expertos. Se considera que ciertos MD pueden ser afectados individualmente por acciones de mantenimiento, mientras que otros no, lo cual contribuye al estado del arte de los modelos con mantenimientos imperfectos. Las mencionadas características del modelo implican que este puede implementarse, en su conjunto, como una nueva compuerta lógica donde, de forma implícita, se modifican las funciones de daño (*Hazard functions*) de cada MD dependiente, dando por resultado, a nivel de componente, curvas de confiabilidad con funciones de riesgo complejas. Los análisis presentados demuestran que la no consideración de las dependencias entre los MD implica una subestimación de la probabilidad de fallo calculada.

Estructura de la tesis

En el Capítulo I se ofrece una disertación del comportamiento de los MD que afectan la confiabilidad de los componentes, específicamente de los álabes de las turbinas de vapor. Se discuten aspectos como el impacto económico de los fallos de los álabes en las centrales de producción de energía, los métodos y programas computacionales para evaluar su confiabilidad, las características de los principales MD que afectan a los álabes de las turbinas nucleares y las técnicas comunes para identificar los MD como parte del proceso de mantenimiento.

Los fundamentos matemáticos de las RB se discuten en el Capítulo II, donde se realiza una revisión bibliográfica del uso de estas en los análisis de confiabilidad y posteriormente de los métodos disponibles para cuantificar las TPC de forma automática a partir del conocimiento de una pequeña cantidad de valores.

Un nuevo método probabilístico que cuantifica la influencia conjunta sinérgica de varias causas o señales en la generación de un efecto, el ERNOR, se desarrolla en el Capítulo III. Sus versiones estáticas y dinámicas son presentadas y el desarrollo a partir de su predecesor, el RNOR, es discutido. El ERNOR es utilizado de forma estática para completar las TPC en el modelo desarrollado en el Capítulo IV y posteriormente para considerar las dependencias dinámicas en el modelo del Capítulo V. Los modelos desarrollados en los Capítulos IV y V contribuyen directamente al objetivo principal de la presente tesis.

En el Capítulo IV es desarrollado el modelo estático, basado en RB, para la identificación de los MD y las ubicaciones susceptibles en turbinas de vapor nucleares. Se describe la concepción de la propia red y su proceso de cuantificación. Finalmente se presentan varios análisis que dan cuenta de la utilidad del modelo.

El Capítulo V está dedicado al desarrollo de un modelo dinámico para considerar la variación de las influencias de los MD en el tiempo. Se presentan los nuevos conceptos y requisitos del modelo, así como la aplicación de mantenimientos enfocados en cada MD de forma individual. Finalmente se muestran diferentes análisis de sensibilidad aplicando mantenimientos en diferentes momentos para comparar los resultados, considerando y desconsiderando las dependencias entre los MD.

Finalmente se presentan las conclusiones generales de la tesis, las referencias utilizadas y dos anexos. El Anexo A contiene la encuesta para determinar los valores para cuantificar los modelos desarrollados en los Capítulos IV y V. El Anexo B presenta los pasos, en mayor detalle, para obtener una TPC para el modelo estático del Capítulo IV.

Capítulo I: Las turbinas de vapor y los mecanismos de daño en los álabes

En el caso de los álabes las estadísticas indican que los fallos pueden ocurrir incluso en el primer año de funcionamiento [1, pp. 5_1-5_4] en industrias a base de combustibles fósiles, antes que el equipo pudiera ser abierto para inspección. A pesar de que en algunas instalaciones el fallo de un álabe nunca se ha producido, o pudiera considerarse como un caso raro, este tipo de componentes cuenta con un amplio historial en diversas industrias. La afirmación consta en el sinnúmero de bibliografías y trabajos científicos que se han dedicado exclusivamente a tratar el tema de los fallos de los álabes y determinar sus causas. Las referencias [2] y [3] son artículos que recopilan brevemente algunos de los casos de fallo de los álabes y también describen las pruebas utilizadas para identificar los MD involucrados. Las referencias [4], [5] y [6] son informes más extensos dedicados a los problemas de las turbinas de vapor, pero se presta especial atención a los MD que afectan los álabes rotatorios. El Manual ASM sobre corrosión [7] ofrece un compendio de artículos sobre el tema y además, los MD relacionados con la erosión, entre otros, y cómo estos pueden interactuar. Información valiosa del comportamiento de los MD en las turbinas se trata en los libros de Sanders [8] y [9] sobre el mantenimiento de componentes de turbinas y el de Leyzerovich [10] para turbinas en plantas nucleares.

La importancia de entender cómo y sobre todo cuándo fallarán los álabes y otras piezas de las turbinas ha hecho que instituciones y grupos de investigación de todo el mundo estudien los MD, combinando esfuerzos, como por ejemplo el *Electric Power Research Institute* (EPRI) [11]–[13]. Esta institución posee dos programas específicos sólo para tratar el tema de las turbinas. El programa 65, enfocado en la turbo maquinaria de vapor, generadores eléctricos y sus sistemas auxiliares, proporciona los recursos dirigidos a los estudios de todos los aspectos de la operación, el mantenimiento y la evaluación de la vida útil de estos equipos. Una síntesis de los trabajos efectuados bajo este programa hasta el 2017 puede consultarse en la referencia [14] o directamente en el sitio web oficial de EPRI [15].

En el estudio de Machniewicz [16], se ofrece un resumen de los diferentes tipos de modelos para estimar el crecimiento de fracturas por fatiga. Sus principales conclusiones son que el uso de cada método depende fuertemente del tipo de material y condiciones de carga, por lo que todos los métodos tienen sus limitaciones de aplicación y que por ende no existe una metodología universal para predecir el comportamiento de las fracturas. Similares conclusiones se obtienen en [17] para el fenómeno de la fatiga de baja frecuencia en álabes de baja presión en una turbina de vapor, donde finalmente se discuten los factores que pueden influir en la variedad de resultados obtenidos para el mismo caso, aplicando diferentes métodos.

Steam Turbine Risk Assessment Program (STRAP) [18] es un programa computacional para optimizar mantenimiento en turbinas. Para el análisis, se divide la turbina en partes principales y estas, a su vez, en sub-partes. Por ejemplo, dentro de lo que en STRAP se denomina rotor, se encuentran los álabes, los cuales, como conjunto y sin prestar atención a la fila donde se encuentran ubicados, se subdividen en varias partes, como la hoja, la raíz, etc. Luego a cada parte se le asignan diferentes MD, el cual resulta ser un enfoque de gran alcance debido a su granularidad, similar al que se busca en esta tesis. Sin embargo, no se considera en el modelo una dependencia de los MD con la fila de álabes, ni tampoco las dependencias probabilísticas entre ellos, resultado de las influencias descritas anteriormente entre los MD, limitaciones que en esta tesis son resueltas.

Otros programas computacionales comerciales han sido desarrollados en ambientes tridimensionales y permiten realizar análisis de vida remanente de los componentes. Entre estos se pueden mencionar BladePro-AF™ y BladePro-CF™ [19], basados en el análisis de elementos finitos. Son paquetes especializados en el análisis de turbinas como parte de ANSYS. Estos incorporan mejoras en el proceso de diseño de los modelos geométricos mediante plantillas paramétricas que facilitan la creación de curvas suaves en correspondencia con las encontradas en turbo maquinaria. Otro con similares conceptos es BLADE-ST™ [20], desarrollado en conjunto con EPRI para ser usado por los fabricantes de turbo maquinaria, consultores y personal de las plantas; siendo útil para el análisis de diseños y causas de fallo. Estos programas incluyen rutinas

predefinidas para hacer análisis de ciclos de vida de las partes, como el método Rainfall, la regla de Miner para el daño acumulado, los gráficos de Goodman, Morrow, etc. Al igual que los anteriores, se basa en la técnica de elementos finitos, donde es posible lograr una gran exactitud en una gran cantidad de puntos simultáneamente si se adoptan los datos de entrada correctos. La exactitud dependerá también de la calidad y el tipo de mallado, que influye en el tiempo de cálculo, por lo que la complejidad del modelo normalmente queda limitada por las capacidades de cálculo disponibles.

LPRimLife (*Low Pressure Rotor Rim-Attachment Cracking Life Assessment Code*) [21] es un código desarrollado por EPRI para la evaluación de la evolución de las grietas en los discos de las turbinas de baja presión, en respuesta a la presencia de grietas en alrededor de un 38% de las turbinas estudiadas en reactores PWR y BWR en el año 1995. En este programa computacional se considera el problema a partir de la introducción de una grieta, que puede ser resultado de ensayos no destructivos. Dado su alcance, se trata de un programa de mecánica de fracturas optimizado para las grietas que surgen en los bordes de los discos donde se anclan los álabes.

Las citadas referencias presentan diversas metodologías para determinar la probabilidad de fallo de diferentes partes de la turbina: rotor, discos, válvulas, carcaza, los álabes, etc. Una característica que dificulta el estudio de la confiabilidad de los álabes es que, para una sola turbina, existen varios pasos donde se extrae la energía del vapor, o simplemente, filas, por lo que la población de álabes es grande y variada comparada con otros componentes constituyentes de la turbina, cuya presencia es menor o única, con condiciones de trabajo más específicas (p. ej., una válvula). Respecto a las condiciones de operación de los álabes y la combinación material-ambiente, que condicionan los MD y sus dependencias, los elementos de una fila pueden tratarse como semejantes, lo cual puede simplificar el estudio de los MD y permite extrapolar resultados y conclusiones a todos los elementos de una fila. Por otra parte, los álabes de una fila son diferentes en los aspectos mencionados, a todos los que se encuentran en otras filas, estableciendo entonces limitaciones en los métodos de cálculo de confiabilidad, explicando el por qué se prefiere tratar a todo el conjunto de álabes como un super componente.

1.1. Comportamiento de los fallos y mecanismos de daño en álabes.

El daño de los componentes de un sistema ingenieril comúnmente involucra tres factores principales: las condiciones ambientales de operación, los esfuerzos mecánicos que actúan sobre el elemento y la susceptibilidad del material a sufrir determinados tipos de daños [22, p. 130]. Los álabes deben soportar altas tensiones mecánicas producidas por las fuerzas centrífugas y las resultantes del cambio de dirección del vapor a lo largo de su trayectoria. Simultáneamente, el vapor se expande a través de la turbina, la temperatura disminuye y la humedad aumenta. Estos cambios en las condiciones ambientales, aunado a las fuerzas de tensión, se exacerban en la sección de baja presión de la turbina.

Las complejas relaciones entre los materiales, las condiciones ambientales y la tensión mecánica determinan la aparición, o no, de ciertos MD. También existen dependencias condicionales entre los propios MD. Por ejemplo, los mecanismos que afectan el acabado de la superficie (como la erosión por impacto de las gotas, la corrosión por picadura y el desgaste entre componentes) pueden aumentar la cantidad de puntos que intensifican las tensiones mecánicas y sirven como puntos de nucleación para el desarrollo de otros mecanismos que propagan el daño, como la fatiga mecánica, la fatiga asistida por corrosión (CF) y el agrietamiento asistido por corrosión bajo tensión (SCC). Desde la perspectiva de una fila de álabes, una turbina de vapor es radialmente simétrica, y teniendo en cuenta que las condiciones ambientales y de estrés mecánico varían a lo largo de la trayectoria del vapor (desde la primera hasta la última fila), cada fila de álabes puede considerarse como una población de elementos similares que comparten características constructivas y operacionales, y como consecuencia, un conjunto específico de MD.

Un gran número de estudios de fallos documentados en la literatura están relacionados con las últimas filas de las turbinas condensantes de baja presión (por ejemplo, L-0 y L-1). Estas filas contienen los álabes más grandes de la turbina para aumentar la eficiencia del equipo y extraer energía a un flujo de vapor que ha perdido la mayor parte de su energía en las filas precedentes. Las tensiones mecánicas aquí son mayores que en las otras filas debido al tamaño de los álabes, aumentando las fuerzas centrífugas,

especialmente en L-0. Del mismo modo, el nivel de humedad y las velocidades lineales son las más altas. Las inestabilidades de flujo, inducidas por la condensación o las variaciones de vacío del condensador por su cercanía, pueden inducir mecanismos de agrietamiento con mayor probabilidad que en las filas frontales. Además, la erosión por goteo, asociada principalmente con las filas después de la Zona de Transición de Fases (ZTF), afecta a los perfiles aerodinámicos de la hoja, principalmente en las partes más externas, alejadas de la raíz. La humedad después de la ZTF también es peligrosa por los conocidos efectos de corrosión localizada (picaduras) inducidos por las especies químicas que se depositan en las superficies, transportadas en las pequeñas gotas que impactan los álabes.

Los primeros álabes de la sección de alta presión, por su parte, son susceptibles al impacto por objetos extraños, más que los demás (esto es más común en industrias a base de combustibles fósiles que en la nuclear), a la vez que los efectos de las admisiones parciales, si aplica, inducen esfuerzos cíclicos generadores de fatiga, que pierden influencia en las filas posteriores. Incluso en turbinas con recalentamiento intermedio, la primera fila de la sección de baja presión pudiera sufrir del mismo tipo de daño, aunque es menos común.

Dentro de una fila, las diferentes partes / porciones de los álabes también están sujetos a diferentes MD. Por ejemplo, las raíces son propensas a friccionarse contra el disco donde van fijadas, formando grietas. La base del álabe (la transición entre el perfil aerodinámico y la raíz), aquí considerada como parte de la porción de la raíz, es propensa a agrietarse por fatiga debido a los cambios de área de la sección transversal. Las puntas de los álabes y las bandas de cobertura están sujetas a una mayor erosión que las zonas cercanas a las raíces porque la velocidad lineal aumenta con el radio. En resumen, se concluye que los MD dependen condicionalmente de la fila, así como de la parte/porción de los álabes.

Aunque las turbinas de vapor nucleares y convencionales tienen la misma función, existen diferencias generales entre las poblaciones, como se describe en [6, p. 3_8], en cuanto al diseño, operación y MD inducidos. Se enfatiza que son diferencias que, en general, se cumplen, pero pueden existir diseños que no lo hagan. En las plantas de

energía nuclear, las presiones de operación en el circuito de la turbina son generalmente más bajas que en las plantas termoeléctricas, por lo que es necesario un mayor flujo de vapor para generar la misma potencia de salida, lo que lleva a diseños con dimensiones más grandes. Como consecuencia, las fuerzas centrífugas son mayores en los álabes de diseños nucleares, por lo que sus revoluciones por minuto (RPM) se limitan para compensar. Las turbinas nucleares generalmente funcionan a 1800 y 1500 RPM para frecuencias eléctricas de 60 y 50 Hz, respectivamente, mientras que los modelos típicos en plantas alimentadas con combustibles fósiles operan a 3600 y 3000 RPM para las mismas frecuencias. Además, la distribución de ZTF difiere entre diseños fósiles y nucleares. La ZTF está típicamente cerca de la fila L-1 en la mayoría de las turbinas fósiles de baja presión y cerca de la región L-3 o L-4 de las nucleares [22, p. 121]. La Figura 1 muestra las distribuciones de fallos de álabes por fila para diseños fósiles y nucleares. Los datos son tomados de [1, p. 1_13].

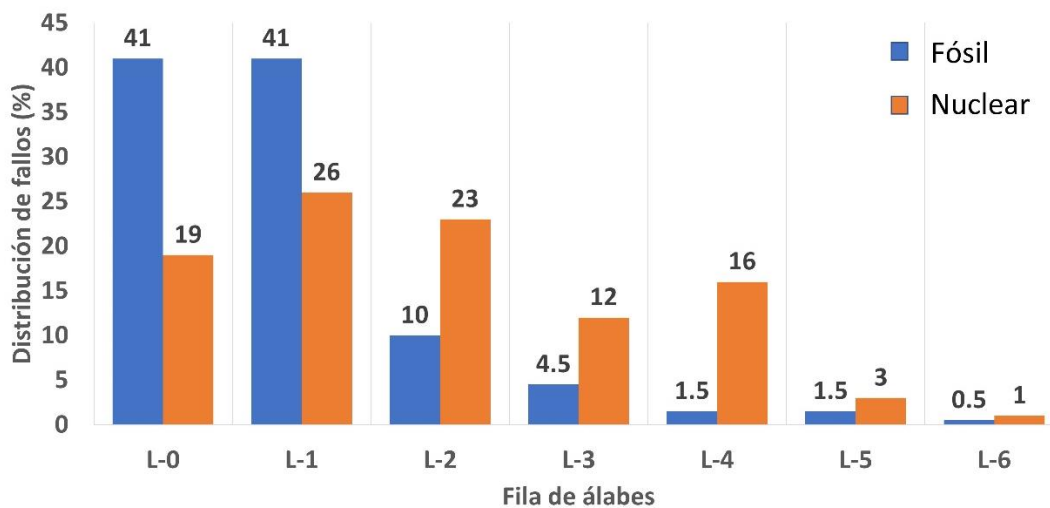


Figura 1: Distribución de fallos de álabes por fila, comparación entre turbinas de baja presión nucleares y fósiles.

La presencia de la fluencia del metal en las secciones de alta y media presión de las turbinas de combustible fósil es un MD que comúnmente afecta a las turbinas de plantas fósiles y no nucleares, debido a la mayor temperatura del vapor en las primeras; de igual forma en las últimas no es común la erosión por partículas sólidas, dada principalmente por el desprendimiento de óxidos de los tubos de la caldera en las plantas fósiles. Por último, el hecho de que las plantas nucleares normalmente se despachan en régimen de

carga base y las fósiles tienden a ciclar la potencia de acuerdo con la demanda, favorece el crecimiento de daño prematuro por fatiga térmica de estas últimas.

El problema de los fallos de álabes en las turbinas de vapor ha sido estudiado por EPRI con mayor énfasis desde la década de los años 80. Fue a inicios de esta década que se realizó un estudio estadístico [1] acerca de los fallos de álabes en las turbinas de vapor de más de 300 MW, como parte de un programa que pretendía destacar los principales problemas existentes y las posibles aristas de investigación en las que debían enfocarse los recursos. En el mismo se encuestaron 68 unidades nucleares y 426 de combustibles fósiles para el período comprendido de 1970 a 1981. La muestra reportó 57 y 366 paradas respectivamente, para un total de 423, donde el fallo de uno o más álabes estuvo involucrado. En su conjunto se estimaron pérdidas totales de alrededor de 1.4 billones de dólares. La mayoría de estos fallos ocurrieron en la sección de baja presión, a la cual son asociadas también la mayor cantidad de costos por reparación y no generación de energía, como se muestra en la Tabla 1, cuyos datos son tomados de [1, p. 1_14].

Tabla 1: Estadística de los fallos de los álabes en las tres secciones de las turbinas (fósil y nuclear).

Tipo de sección de la turbina por presión	# de interrupciones	Horas de interrupción	Gastos USD en reparación de álabes	Pérdidas estimadas por no generación
Baja	336.00	147,291.50	77,990,500	796,157,500
Alta	47.25	35,365.50	3,942,000	184,214,000
Intermedia	37.75	31,563.00	5,523,000	176,260,500
No identificada	2.00	2,160.00	0	8,100,000

Dentro de estas tres secciones generales de las turbinas (alta, media y baja presión), se reportó que el 75% de todos los fallos de la turbina de baja ocurrieron en las filas L-0 y L-1, el 58% de los fallos de la sección intermedia ocurrieron en la primera fila y en la de alta este dato corresponde al 43%, también en la primera fila.

La determinación del tiempo que estadísticamente demoraban las unidades en fallar por causa de los álabes, luego de efectuarse alguna revisión, fue otro dato calculado. Este tiempo se organizó en dependencia de si el elemento falló de forma imprevista (paro forzado), o si se encontraba fallado en una revisión planificada. Se determinó que luego

de dos años de haberse efectuado la última inspección, existía un 80% de probabilidad de que se generara un paro forzado a causa del fallo de los álabes, mientras que la probabilidad de un paro planificado era de un 59%. Lo anterior significa que se reportó un tiempo de vida relativamente corto (al menos en el período estudiado), donde la probabilidad de que se manifestara el fallo de un álabe con casi 100% de seguridad rondaba los 5 años.

De la encuesta, se determinó la ubicación de los fallos de los álabes por secciones. Los datos de la Tabla 2 han sido recabados de [1, p. 5_4]. La mayoría de los fallos de los álabes ocurren en la sección de baja presión, seguido por la sección de alta. En ambas la zona de la hoja del álabe es la más afectada, mientras que, para la sección de intermedia, resulta ser la zona de la cubierta de los álabes. Las siglas NA significan no aplica.

Tabla 2: Lugares donde se producen fallos de álabes en turbinas (fósil y nuclear).

Lugar del fallo	Cubierta	Alambre	Hoja	Raíz
Baja presión	111	83	164	64
por ciento	26	20	39	15
Intermedia	49	NA	12	7
por ciento	72	NA	18	10
Alta presión	23	NA	35	26
por ciento	27	NA	42	31

La Tabla 3 presenta algunos puntos destacados de los resultados de [1] relacionados con las consecuencias económicas de los fallos de los álabes en turbinas nucleares y fósiles. Todos los indicadores totales en la sección superior son más altos para las unidades alimentadas con combustibles fósiles, como se espera de la cantidad de paradas para ambos tipos de plantas y el hecho de que hay menos plantas de energía nuclear que las fósiles consideradas en la encuesta. En la parte inferior de la tabla se normalizan los valores respecto a las paradas para ofrecer una mejor comparación de los indicadores, independientemente de la cantidad de plantas. En la década de 1970 a 1981, el promedio de pérdidas debido a energía no producida por paradas fue muy similar para ambos tipos de plantas. El tiempo de inactividad por parada (horas de paro por parada) fue ligeramente mayor para las plantas fósiles. Sin embargo, los costos

asociados con el reemplazo de álabes por parada se estimaron muy diferentes, siendo los gastos en plantas nucleares aproximadamente el doble que en las plantas fósiles.

Tabla 3: Consecuencias económicas de los fallos de los álabes.

Tipo de unidad	\$ replazo de álabes	Hrs de paro	\$ Energía no producida	Paradas forzadas
Fósil	67,901,000*	191164*	1,015,092,000*	131*
Nuclear	19,555,000*	25216*	149,640,000*	25*
	\$ replazo de álabes/parada	Hrs de paro/parada	\$ Energía no producida /parada	Razón de paradas forzadas
Fósil	185,521	522	2,773,475	0.35
Nuclear	343,070	442	2,625,263	0.44
Total de paradas: Fósil 366*; Nuclear: 57*. Los datos con * fueron tomados de [1], los demás fueron calculados.				

La turbina está directamente relacionada con el balance de planta, lo cual es especialmente importante en las de energía nuclear porque los reactores hacen Scram (apagado repentino del reactor) después de un apagado súbito de la turbina. El apagado repentino del reactor implica la activación de los sistemas de seguridad y enfriamiento, luego los trabajos de mantenimiento, la realineación de los sistemas de seguridad de la planta y la puesta en marcha. Dichas acciones pueden durar varios días, incluso meses, dependiendo de la magnitud del fallo y, en cualquier caso, se deja de producir energía.

Casi dos décadas después, en 2004, es publicado otro estudio de EPRI [23], esta vez enfocándose en todos los componentes (no solamente los álabes) de las turbinas de reactores PWR y BWR en el período de 1982 a 1998. El estudio comprendió 104 reactores, de los cuales 83 reportaron eventos en sus turbinas. Con este fin, se acudió a la base de datos NERC-GADS (*North American Electric Reliability Corporation - Generating Availability Data System*) para los eventos no planeados que involucran actividades de mantenimiento. Se encontró que de los eventos que han sido correctamente asociados a componentes específicos (en la base de datos existen eventos en los que no se especifica el componente afectado), el 17% se atribuye a las secciones de alta y baja presión, que en su mayoría corresponden a fallos de los álabes. Este relativamente pequeño aporte de eventos representa un importante 59% del total de horas de generación perdidas por problemas en las turbinas principales. De los fallos

conjuntos de las secciones de alta y baja presión, los reactores PWR presentaron 19 eventos con 8363 horas de pérdida de generación, inferior al dato de los BWR de 23 eventos con 23226 horas. Otro dato determinado es que la tasa de fallos de la turbina, como super componente, se comportó en el rango de 0.2 a 0.25 /año, o sea, un promedio de un fallo entre 4 y 5 años.

1.2. Mecanismos presentes en las turbinas de centrales nucleares

En la presente sección se discuten los MD que típicamente están presentes en las filas de álabes de las plantas nucleares, así como aspectos de sus dependencias. Los MD descritos a continuación son considerados en este trabajo.

1.2.1. Impacto por gotas

Es el choque continuo de pequeñas gotas de condensado en las últimas filas después de la ZTF. Su término en inglés es *droplet*. Las gotas se originan dentro de los canales de vapor, en las superficies de los álabes fijos aguas arriba, donde existe una capa delgada del líquido, el cual se escurre de la superficie debido al paso del vapor e impacta contra las superficies de los álabes rotatorios. La erosión se produce principalmente en los bordes anterior y posterior de la superficie aerodinámica por microgotas de agua que pueden alcanzar la mitad del milímetro [5, p. 6_1], [24], [25]. Este fenómeno es peor en cubiertas y en general las porciones que están en los extremos radiales debido a una mayor velocidad lineal, que pueden alcanzar los 750 m/s [26] en algunos álabes de la última fila de turbinas de baja presión. El impacto provoca que, después de varios años, se erosione y aumente la rugosidad de la superficie [27, p. 2], con una reducción de eficiencia de la fila de álabes por irregularidades en la trayectoria del vapor.

Una cadena de sucesos peligrosos es cuando la erosión puede servir como un concentrador de estrés mecánico para iniciar un proceso de fatiga. La erosión puede generar bordes afilados, irregulares o ásperos, que también puede exacerbarse si la pérdida de material por erosión cambia la frecuencia natural de los álabes [23, p. 5_24] y entran en resonancia por la interacción con otra frecuencia natural de la turbina [5, Sec. 4.1]. La erosión por partículas sólidas, más común en álabes de reacción, es poco usual en unidades con temperaturas menores a los 537°C, por lo que no es un problema frecuente en plantas nucleares [5].

1.2.2. *Fatiga mecánica simple*

Se refiere a la fatiga sin asistencia ambiental o donde el ambiente juega un papel despreciable. Es un agrietamiento producido en componentes que experimentan cargas mecánicas cíclicas, propagándose hasta que se produce la fractura. La vida de un componente sometido a fatiga puede estar limitada por imperfecciones en el material, como burbujas, poros y frecuentemente por irregularidades en la superficie de la pieza como rugosidades o bordes afilados producto de erosión, malos acabados, o daños mecánicos por otras causas, huecos maquinados y cambios de sección transversal, que crean zonas de concentración de estrés mucho más grandes que las promedio para el volumen del componente [5, Sec. 4.1]. En los álabes de las turbinas de vapor, las cargas mecánicas cíclicas pueden provenir de la frecuencia de paso del álabe, el aleteo o las interacciones con otros armónicos del sistema.

En las turbinas de vapor, la fatiga de bajo ciclo suele presentarse en la forma de fatiga térmica por los cambios de temperatura que experimenta el equipo en los encendidos y apagados. Se crean ciclos donde los parámetros de trabajo poseen un patrón bastante predecible para cada unidad: encendido, carga nominal (con fluctuaciones de potencia debido a variaciones en la demanda de energía por los consumidores y poco aporte al daño), y apagado frío o tibio. Este tipo de problemas es común en turbinas de gas para generación de electricidad y un problema mayor en las turbinas de las aeronaves. No es usual en unidades nucleares, ya que su régimen de trabajo es en carga base, con pocas variaciones y pocos ciclos de apagado/encendido respecto a los equipos a base de combustibles fósiles.

La fatiga de alto ciclo suele presentarse en los álabes si éstos son pobremente diseñados o su interacción con frecuencias de trabajo provenientes de otras partes del sistema no han sido tenidas en cuenta apropiadamente para el cálculo de todo el equipo. Particularmente la coincidencia de frecuencias de diferentes partes del equipo y armónicos puede estudiarse con la ayuda del diagrama de Campbell [5, p. 4_7], el cual es muy útil, para determinar los peligros asociados a las resonancias durante el arranque y apagado de la turbina. De hecho, en los procesos de encendido y apagado los tiempos de permanencia en ciertos intervalos de RPM se limitan (esto aparece claramente

reflejado en los procedimientos que usan las plantas con este fin), en dependencia del grado de amplificación de las oscilaciones que puede alcanzarse, que puede ser destructivo con pocos ciclos. El conocimiento de estos valores es de especial importancia para los operadores de cualquier turbina.

La resonancia en los álabes también puede presentarse por cambios en las frecuencias naturales con el paso del tiempo debido a fenómenos de erosión con pérdida de masa y/o cambio de geometría. La fatiga es propensa a ocurrir en los álabes de control de las turbinas de alta presión con control por admisión parcial. En las turbinas de baja presión, con álabes largos, el problema se agrava ya que puede presentarse el fenómeno conocido como aleteo (*flutter*, en inglés), principalmente en L-0 por inestabilidades aerodinámicas producidos por alta presión del condensador o un bajo flujo volumétrico que provoca turbulencias que excitan los elementos, dañando las zonas próximas a las raíces en poco tiempo. Otro fenómeno que genera fatiga es la vibración torsional inducida desde el generador por desbalances de fase, la cual se transmite hacia el rotor de la turbina, sacudiendo los álabes de un lado al otro.

1.2.3. Corrosión de la superficie por picaduras

Debido a que los materiales utilizados en los álabes de turbinas son aceros inoxidables y al bajo contenido de oxígeno en el vapor, la corrosión química uniforme no suele ser un problema para estos elementos. Por otra parte, el contenido de humedad y la concentración de especies químicas como cloruros y sulfatos, incrementada por el mismo proceso de condensación [28, p. 7], hace que la corrosión electroquímica, sobre todo la localizada (en inglés, *pitting*), sí sea un problema mayor en discos y álabes. La corrosión localizada se manifiesta como picaduras con aspecto de cráter con profundidad variable que incluso pueden atravesar de lado a lado las partes más delgadas de la hoja en casos extremos.

Para que ocurra este fenómeno es necesaria la presencia del electrólito, por lo que en las zonas más calientes no suele ocurrir y los químicos se adhieren a las superficies del paso del vapor como un polvo inerte en estas condiciones [5, p. 4_10]. La zona húmeda comúnmente se localiza en la sección de baja presión. En esta sección, a pesar de existir humedad, la corrosión se manifiesta en las filas donde se encuentra la ZTF. En la zona

de transición aparecen gotas de agua con niveles de cloruros de ordenes más elevados que los encontrados en el agua de alimentación. A medida que la capa filmica de condensado se evapora, los cloruros quedan depositados sobre las superficies de los álabes y en las hendeduras de las raíces con los discos, provocando la corrosión. Sin embargo, la mayor parte de este fenómeno ocurre cuando la turbina es apagada sin apertura de carcasa. En estas circunstancias el oxígeno entra a la turbina, la temperatura decrece aumentando la humedad, y se acelera la reacción química de las deposiciones sobre el metal, creando la picadura. Incluso en la sección de alta presión donde normalmente los químicos están secos en forma de polvo durante la operación, en el apagado se humedecen y reaccionan con el metal. Dicha situación desfavorable puede mitigarse si al apagar el equipo se introduce aire seco y caliente para evitar el punto de rocío y la condensación. La otra opción es abrir la turbina y limpiarla rápidamente.

Una vez que el ataque corrosivo a la superficie se evidencia, es necesario el juicio ingenieril para decidir la acción: si dejarlo como está o eliminar las picaduras por algún proceso de pulido o desbaste de material. Sin embargo, si la causa raíz del problema no es resuelta, las picaduras vuelven a aparecer.

Aunque acciones correctivas son tomadas para tratar la superficie de los componentes del álabe, los mayores y más riesgosos problemas de disponibilidad y seguridad no son directamente las picaduras, sino sus consecuencias al actuar como intensificadores de estrés localizados que pueden servir de inicio a procesos agrietamiento asistido por corrosión [34]. Así, las picaduras nuclea grietas que pueden ser propagadas por CF y SCC [29, p. 2_11] [30].

1.2.4. Agrietamiento asistido por corrosión bajo tensión

Es un tipo de agrietamiento que le ocurre a materiales susceptibles ante la combinación de tensiones mecánicas, la presencia de sustancias corroyentes y de humedad, que de manera sinérgica disminuyen la resistencia del material [5, pp. 4_11-4_15]. En inglés se le conoce como *Stress Corrosion Cracking*, por lo que se usarán las siglas SCC en esta tesis.

La susceptibilidad del material puede aumentar con la aplicación de procesos tecnológicos como la soldadura, en la que, debido a la temperatura, se crean sitios de alta susceptibilidad por efecto de la difusión y pérdida de elementos aleantes como el Cromo. Además de la susceptibilidad del material, debe estar presente un medio corrosivo. Existen muchos químicos que pueden promover el SCC, por ejemplo, el cloro; sin embargo, también hay algunos usados para el tratamiento de agua, en actividades de mantenimiento como lubricantes y refrigerantes del maquinado, que pueden quedar si luego del mantenimiento las superficies no son correctamente limpiadas. Debe existir esfuerzo mecánico de tensión, externo o residual. Los análisis de diversas causas de fallo y en laboratorio han demostrado que un esfuerzo de tracción de alrededor del 50 al 60% del límite elástico ha sido suficiente para iniciar la propagación de una grieta [5]. En el caso del SCC, la presencia de un ambiente corrosivo en el material susceptible puede implicar una reducción del esfuerzo necesario para provocar daño, mismo que no ocurre en un ambiente inerte.

En contraste con la fatiga y la CF, la grieta principal del SCC muestra fisuras secundarias que se ramifican de la primera [5, Sec. 4.3]. Según el Modelo de disolución de deslizamiento, se hipotetiza que este fenómeno se produce debido a una ruptura de la capa pasiva o protectora en la punta de la grieta debido al esfuerzo de tensión. Una vez rota, el metal se encuentra desprotegido de los químicos del electrólito que lo disuelven, al tiempo que la grieta avanza comúnmente por la frontera de grano, hasta que la capa pasiva se recrea. El proceso vuelve a comenzar por la nueva ruptura de dicha capa. Este modelo es altamente aceptado y explica la necesidad del medio corrosivo, el esfuerzo, y la susceptibilidad del material en dependencia de la velocidad de regeneración de la capa pasiva.

1.2.5. Fatiga asistida por corrosión o corrosión fatiga

Se manifiesta ante la combinación de un ambiente corrosivo y cargas mecánicas cíclicas. En inglés se le conoce como *Corrosion Fatigue*. El efecto de un ambiente corrosivo es una reducción en la resistencia a la fatiga del material, la cual puede observarse en los diagramas de esfuerzo *versus* ciclos (diagramas S-N). En muestras similares, las que se encuentran sometidas a un ambiente corrosivo, presentan una reducción significativa de

la cantidad de ciclos necesarios para obtener un daño, en relación con las que se encuentran en un ambiente inerte. Incluso, pueden presentarse ejemplos de materiales que en un ambiente inerte no presentan fatiga y cuando son sometidos a corrosión, presentan una pobre resistencia a la fatiga en ese medio específico. Resumiendo, la CF se puede presentar para un material en presencia de corrosión, a menores esfuerzos y/o a menor cantidad de ciclos.

Aunque la presencia de picaduras no es un requisito indispensable para el desarrollo de la CF [31], éste fenómeno se facilita comenzando las grietas en las picaduras u otros puntos donde los esfuerzos se han intensificado. La CF es común luego de la ZTF, donde la humedad es alta y las especies químicas están presentes [32], [33]. También son características las marcas de playa que se pueden observar en la superficie de la fractura desde el punto de nucleación hasta una zona de fractura dúctil correspondiente a la sección remanente que falla de golpe al no soportar los esfuerzos.

1.2.6. Fricción

Es el desgaste por fricción que ocurre entre las superficies de elementos cuyo movimiento relativo se encuentra limitado a amplitudes que pueden llegar a ser tan pequeñas como unidades de nanómetros [31, pp. 817–829]. En inglés se le conoce como *fretting*. La fricción se puede encontrar en la unión entre piezas que deberían estar perfectamente unidas de acuerdo con su propósito de diseño, sin embargo, las fuerzas oscilatorias hacen que las superficies en contacto se friccionen entre sí. Tales casos son las superficies de contacto entre los discos de una turbina contra el rotor, o las raíces de los álabes contra el propio disco. En este último caso las fuerzas ejercidas sobre la superficie aerodinámica del álabe por el vapor hacen que las superficies de contacto entre éste y el disco que lo sujeta presenten movimiento relativo del orden de los micrómetros, suficiente para friccionar los metales y desprender pequeñas virutas que incrementan el daño actuando como un abrasivo, provocando más daño en un ciclo de retroalimentación positivo. El efecto neto es una aceleración en la iniciación de la grieta en estas superficies y en la velocidad de propagación (las virutas se introducen en la grieta e incrementan el esfuerzo de tensión en la punta, abriéndola), o sea, una reducción

de la resistencia a la fatiga [34]. Se encontró que esta reducción era del 85% de la vida útil a la fatiga en la raíz de un álabe en una planta de energía nuclear que falló [35] [36].

1.3. Técnicas para identificar los MD en turbinas

Con la turbina en funcionamiento existen varios métodos de monitoreo de la condición de los álabes. El monitoreo de la vibración medida en los cojinetes es de las más populares debido a su relativa simplicidad respecto a otras técnicas más invasivas. Se ha demostrado que los patrones de vibración pueden cambiar cuando existen deformaciones de un álabe (p. ej., por fluencia o impacto de objetos), pérdida de masa (p. ej., se suelta una porción del álabe o por erosión severa), álabe suelto (con holgura excesiva), incluso la presencia de grietas [37] [38] [39] y por supuesto, la resonancia siempre provoca una alteración de los patrones vibratorios. Esta técnica comúnmente sólo permite saber si existe algún problema en los álabes, aunque puede confundirse con vibraciones procedentes de otras partes de la turbina. La medida de la vibración a partir de la frecuencia de paso de álabe es un método más exacto, ya que permite monitorear álabes individualmente. Los sensores no miden directamente la vibración mediante acelerómetros, sino que son empleadas las corrientes Eddy, técnicas magnéticas, microondas, ópticas como láser e infrarrojos [40] [41]. Son útiles para detectar cambios en las vibraciones que producen fatiga de alto ciclo. Debido a que los sensores deben estar dentro del flujo de vapor, son susceptibles a deterioro, además, requieren de modificaciones a la carcasa de la turbina para su instalación, lo cual es una limitante cuando numerosos sensores son requeridos. Por consiguiente, no todas las filas se monitorean, sólo las más susceptibles según la experiencia (p. ej., L-0).

Monitorear la condición de los álabes con la turbina en funcionamiento es un reto debido a que los elementos se encuentran dentro de las fronteras del vapor, y en movimiento, siendo métodos indirectos de medición de vibración que se correlacionan con un estado operativo indeseado de los álabes, como la resonancia. Por otra parte, la vida útil de la instrumentación se ve limitada. Buenos resultados se obtienen en la determinación del inicio o empeoramiento de un problema debido al cambio de los parámetros medidos, sin embargo, determinar exactamente dónde está el fallo, su extensión y qué tipo de

mecanismo lo rige sigue siendo una tarea posterior que requiere la inspección directa de los componentes.

Teniendo en cuenta la metodología expuesta en la guía para la determinación de causas del fallo de los álabes [29], la identificación de los MD se encuentra en la primera de tres fases enfocadas, en última instancia, a corregir la turbina para impedir la repetición de los fallos. La correcta identificación de los MD es vital para las subsecuentes investigaciones y acciones de mantenimiento. De la primera fase, enfocada en la determinación del (los) MD responsables del fallo mediante la recopilación y análisis de la evidencia disponible utilizando diferentes técnicas, dependerá si la solución a tomar requiere mayor o menor esfuerzo, recursos económicos y tiempo. Las soluciones pueden ser de recuperación: reparar los álabes afectados, reemplazarlos con un carácter provisional o permanente; o pueden ser de investigar más a fondo el problema en fases posteriores, es decir, ganar tiempo con una solución provisional, aplazando la solución definitiva durante algunas semanas. En el referido reporte se exponen los MD más importantes que afectan a los álabes de turbinas de vapor. De forma tabular se describen las principales características o evidencias que estiman o desestiman la hipótesis de que el fallo sea causado por uno(s) u otro(s) MD, sin embargo, es señalado también que los MD pueden ser confundidos, mal identificados, debido a que poseen características muy similares (p.ej., morfología de la grieta). Es muy parecido al proceder de un médico en la identificación de una enfermedad a través de los síntomas (evidencias) de los que se dispone para descartar o soportar conjeturas o hipótesis. Una incorrecta o demorada identificación de los MD puede resultar en la repetición prematura del mismo fallo y pérdidas económicas considerables.

La observación a simple vista o con ayuda de instrumentación óptica es la primera tarea de cualquier inspección, ya sea preventiva o correctiva. De esta se determinan las primeras evidencias, como la presencia o no de erosión, picaduras, agrietamientos, los lugares donde son encontrados los daños y su extensión. Con esta información, conjeturas o hipótesis pueden conformarse para proseguir en las siguientes acciones de mantenimiento. Estas observaciones pueden realizarse con la turbina abierta, ya sea porque falló o porque se realiza un mantenimiento mayor, o con la turbina cerrada en

mantenimientos de mediano alcance o de corta duración, a través de puertos de inspección o las entradas y salidas del vapor de la turbina [42].

El uso de puertos de inspección limita el alcance de las observaciones. Durante dicho procedimiento lo común es introducir herramientas ópticas que permiten inspeccionar determinadas filas de álabes, comúnmente los últimos de la sección de baja presión y los primeros de la sección de alta. Se utilizan fibroscopios, boroscopios y sondas de video [43] [37], aunque la tecnología sigue avanzando, brindando nuevas capacidades. Existen modelos de turbinas que poseen mayor cantidad de puertos de inspección, permitiendo una mejor verificación, pero existen filas fuera del alcance de los medios ópticos que no pueden observadas correctamente. Desventajas de este método son: que existen filas de álabes ocultas a la observación; de las filas observables, existen porciones de los álabes que quedan fuera del rango de observación, como por ejemplo la zona de fricción de las raíces debido a que requiere desmontaje; la posibilidad de identificar mecanismos adecuadamente depende de la resolución de la herramienta óptica; y por último, la implementación de técnicas más complejas de exámenes no destructivos (END) es limitada.

La opción de levantar la carcasa superior de la turbina y posiblemente sacar el rotor para su desmontaje suele presentarse en mantenimientos capitales o cuando ha ocurrido un fallo que amerite dicho esfuerzo e inversión monetaria. Se estima que el desmontaje de las carcasas externa e interna puede tomar de 2 a 10 semanas [42]. La opción permite la inspección detallada de todos los álabes y el proceder con END como ultrasonido, líquidos penetrantes, partículas magnéticas y la recolección de muestras para análisis en laboratorios. El envío de los álabes a los laboratorios de análisis de materiales proporciona mayor detalle en la identificación de los mecanismos responsables del fallo. Con este fin, muestras seleccionadas son analizadas. Técnicas fractográficas posibilitan definir los MD con mayor exactitud. Este tipo de proceder requiere de mayor inversión y tiempo, de 2 a 4 semanas son estimadas [29, p. 3_3], además del tiempo que toma el desmontaje de la turbina y su inspección en el sitio.

1.4. Resumen y conclusiones parciales: mecanismos de daño y turbinas

En el presente capítulo se han estudiado los mecanismos de daño que afectan los álabes rotatorios de las turbinas, haciendo énfasis en las de vapor y de tecnología nuclear. Con este propósito, se ha revisado la literatura, abarcando un amplio período de tiempo y una variedad de fuentes como reportes de EPRI, libros, y artículos de revisiones bibliográficas y de investigación. De este estudio se extraen las siguientes conclusiones:

1. En un componente pueden coexistir varios MD simultáneamente, los cuales son las causas inmediatas del fallo.
2. El desarrollo de un MD incrementa la probabilidad de fallo del componente, pero a su vez, incrementa la probabilidad de que otro MD provoque el fallo del mismo componente.
3. La probabilidad de fallo de un componente es dependiente de las probabilidades condicionales de los MD, por lo que es necesario considerar eventos dependientes para su análisis.
4. Considerando lo anterior, el nivel de granularidad de los análisis de confiabilidad en los componentes puede y debe aumentarse para analizar causas de los fallos, es decir, sus MD, y con ello obtener un mejor entendimiento de los procesos que contribuyen a la indisponibilidad.

Específicamente para las turbinas se concluye que:

5. Los álabes dentro de las turbinas principales de vapor constituyen una población de cientos de elementos similares, donde el fallo de un solo elemento puede indisponer la planta. Tales fallos requieren períodos de mantenimiento prolongados y, potencialmente, el reemplazo de componentes internos costosos que pueden causar millones de dólares en pérdidas generales y en costos de reemplazo de energía durante el período en que la producción se interrumpe.
6. Dado que los álabes se encuentran dentro de las fronteras del vapor, es difícil determinar exactamente si estos se ven afectados por uno o más MD. La tarea de identificación los MD relacionados con los fallos es crítica para el proceso de mantenimiento y consume largo tiempo de éste, existiendo la posibilidad de omitir o mal identificar los MD a pesar del compendio de técnicas que se complementan

para este propósito. Lo anterior es especialmente cierto si el trabajo de mantenimiento e inspección de la turbina se realiza a través de puertos de inspección con herramientas de inspección remota y bajo restricciones de tiempo.

7. De entre las secciones de alta, intermedia y baja presión de la turbina principal, la de baja presión es la más susceptible a presentar fallos. La condensación del vapor, presencia de sustancias corrosivas y álabes más grandes que provocan mayores esfuerzos son los principales factores.
8. Las turbinas nucleares poseen, en general, menor cantidad de MD que las turbinas de otras industrias y tecnologías con menores estándares de calidad de mantenimiento o ambientes más hostiles de trabajo, por lo que, para fines demostrativos, esta tesis se concentra en los MD de turbinas de centrales nucleares, sin perder generalidad en los razonamientos que aquí se exponen.
9. Una de las dificultades mayores en el estudio de los álabes es la gran diversidad de modelos geométricos, materiales y condiciones de trabajo que existen entre los diferentes modelos de turbina. Para una misma turbina, dicha diversidad se manifiesta entre las filas que la componen y las diferentes partes del álabe. La gran diversidad en la población de álabes provoca que en los análisis de confiabilidad se asuma como un super componente para simplificar, o los análisis se enfocan en condiciones muy particulares de operación, por lo que los resultados y métodos son específicos y de limitada extrapolación
10. La turbina es un sistema que varía sus condiciones de operación a lo largo del eje axial, por lo que, desde el punto de vista de los álabes, cada fila se puede considerar como constituida de una población de elementos (álabes) similares, sometidos a iguales condiciones ambientales y de estrés mecánico.
11. Al ser un sistema rotatorio, la turbina posee simetría radial, por lo que, para los álabes, las condiciones ambientales y de esfuerzo mecánico poseen dicha simetría.
12. Los MD que afectan a los álabes de las turbinas son condicionalmente dependientes en términos probabilísticos, de la presencia de otros MD, de la fila de los álabes y de la parte del álabe que se esté analizando, con fundamentos en las conclusiones 2, 3, 10 y 11.

13. Debido a la importancia económica de la turbina en las plantas de generación de energía y a las deficiencias existentes en el proceso de identificación de los MD, se hace necesario el desarrollo de modelos probabilísticos que suplementen las técnicas existentes para una mejor identificación y así contribuir con información en la toma de decisiones de mantenimiento.

Capítulo II: Redes Bayesianas

En el capítulo anterior fueron analizadas las características que distinguen a los mecanismos de daño que afectan a los álabes. Específicamente se concluyó que estos poseen dependencias condicionales, de forma que la presencia de uno incrementa la probabilidad de ocurrencia de otro. Los MD están conectados entre sí a través de estas dependencias, aunque también existen independencias. A lo anterior, se le añade el hecho de que los MD y sus dependencias también dependen de la ubicación dentro de la turbina, en específico de la parte del álabe y de la fila de interés. Es por esta razón que ciertas ubicaciones dentro de la turbina son más o menos susceptibles a fallar de ciertos mecanismos y de otros no.

También se discutieron aspectos económicos de los fallos de las turbinas, específicamente de los álabes, y la importancia que tiene el mantenimiento en la prevención y repetición de los fallos. La inspección, con el objetivo de identificar correctamente los mecanismos involucrados en los fallos, o que se encuentran desarrollando el fallo, es una tarea crítica para recopilar evidencias y hacer conjeturas que influyen las decisiones en los subsiguientes pasos de mantenimiento. Los MD son propensos a ser pasados por alto o mal identificados a pesar de la variedad de técnicas disponibles.

Teniendo en cuenta las problemáticas discutidas, se hipotetiza que las redes bayesianas ofrecen una solución adecuada para modelar las dependencias condicionales que existen entre los MD, y de estos con la ubicación de los álabes en las turbinas de vapor, proporcionando una herramienta para el análisis de los MD que contribuyen a los fallos.

Bajo esta sub-hipótesis, el objetivo es construir, como primer modelo, una herramienta de análisis para la identificación de los MD a partir de la evidencia disponible en el mantenimiento de la turbina de vapor, complementándose con las técnicas disponibles para este propósito, favoreciendo la toma de decisiones de mantenimiento con nueva información que contemple las dependencias condicionales entre los MD y su relación con las partes susceptibles de la turbina.

Este objetivo se desarrolla completamente en el Capítulo IV, pero antes, es necesario evaluar aspectos como los fundamentos matemáticos de las RB y su cuantificación para determinar si estas poseen las capacidades necesarias para construir dicho modelo o herramienta y, en su caso, dar solución a las limitaciones encontradas.

2.1. Fundamentos de las Redes Bayesianas

Las redes bayesianas son gráficos acíclicos dirigidos (DAGs, del inglés Directed Acyclic Graphs) [44]. Su representación gráfica consta de nodos y flechas o arcos. Los nodos representan variables aleatorias (VA) discretas con múltiples estados. Estos nodos están conectados mediante arcos, cuyo sentido va del nodo padre al hijo, denotando una dependencia condicional de las probabilidades de los estados del hijo respecto a una combinación de los estados de los padres. La información es ordenada dentro de las TPC, en cuyas celdas se albergan las probabilidades condicionales correspondientes a cada combinación de estados de los padres. Un nodo padre puede tener varios hijos y un hijo puede tener varios padres. En otras palabras, un arco dirigido de un nodo a otro se puede interpretar como una relación de causa-efecto (de padre a hijo) o una dependencia estadística que se puede convertir en una probabilidad condicional de un fenómeno dado otro, respaldado por modelos físicos o varias observaciones.

La probabilidad conjunta de las n VA X_i , que tienen un conjunto de estados x_i contenidos en un RB, se puede calcular a través de la regla de la cadena de probabilidades condicionales:

$$P_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_2, x_1) * \dots * P(x_2 | x_1) * P(x_1) = \prod_i P(x_i | x_{i-1}, \dots, x_2, x_1) = \prod_i P(x_i | px_i) \quad (1)$$

Dado que algunas VA no están condicionadas por todas los demás que conforman la red (solo por los padres), x_{i-1}, \dots, x_2, x_1 representan los estados de los padres de X_i , denotados por px_i en la última igualdad.

La principal fortaleza de las RB es su capacidad para hacer inferencias a través de su estructura cuando se introducen nuevas evidencias en uno o varios nodos para determinar la probabilidad posterior de los demás. Este proceso se conoce como

actualización de creencias o propagación de probabilidades. La inferencia directa o razonamiento predictivo se produce cuando se introduce evidencia en un nodo padre y las distribuciones anteriores (*priors*) correspondientes de los estados de sus hijos se actualizan a las distribuciones posteriores. Considere, a modo de ejemplo, el caso de una relación simple de dos VA: nodo A como padre de B. La probabilidad de un estado fijo "b" de B condicionado por todos los "m" estados a_j de A es:

$$P(B = b) = \sum_{j=1}^m P(B = b, A = a_j) = \sum_{j=1}^m P(B = b|A = a_j) * P(A = a_j) \quad (2)$$

La expresión (2) es la ley de probabilidad total, donde la regla de la cadena se usa implícitamente para factorizar las probabilidades condicionales. Esto significa que la probabilidad del estado de un nodo hijo (aquí, un estado fijo b de todo el conjunto de estados b_i) se calcula como la suma ponderada de las probabilidades de los estados a_j pertenecientes a A. Cuando la distribución de probabilidades de los estados a_j cambia, entonces la probabilidad del estado consultado $P(B = b)$ también lo hace.

Sin embargo, el potencial de las RB se concentra no solo en inferir las probabilidades de los hijos, dados los padres, sino también en determinar las probabilidades de los estados de los padres dada la evidencia introducida en sus hijos. Al proceso se le conoce como análisis causal o razonamiento de diagnóstico y se cuantifica mediante la Regla de Bayes. En el ejemplo de B con padre A, el nodo A puede interpretarse como la causa de B, o que B es la consecuencia de A. Entonces, la probabilidad de un estado fijo "a" de la causa A (es decir, $A = a$), puede conocerse dada la observación o conocimiento de la probabilidad de la consecuencia, es decir, el estado fijo "b" de B. Matemáticamente esta relación se expresa como:

$$P(A = a|B = b) = \frac{P(B = b|A = a) * P(A = a)}{P(B = b)} = \frac{P(B = b|A = a) * P(A = a)}{\sum_{j=1}^m P(B = b|A = a_j) * P(A = a_j)} \quad (3)$$

La ecuación (3) permite consultar las probabilidades de los nodos padres dado el conocimiento de los estados del hijo. En redes más complejas con varios nodos, estados y conexiones, estas ecuaciones se vuelven más complejas, siendo poco práctico el

cálculo sin las RB. En problemas reales, los tipos de razonamiento (causal o diagnóstico, y directo o predictivo) se combinan para propagar la evidencia en redes con estructuras complejas [45, Fig. 53].

Dadas las características de los BN, se constata que son herramientas muy atractivas para manejar varias VA condicionalmente dependientes y de múltiples estados, como los MD. Su capacidad para realizar inferencias o actualización de creencias en cualquier dirección es una forma efectiva de cuantificar estados o características de componentes no observados dadas observaciones de variables de proceso o incluso subsistemas dependientes o estados de componentes. Además, los modelos de BN tienen la flexibilidad de proporcionar resultados incluso cuando hay variables cuyo estado es total o parcialmente desconocido. Estas características hacen que las RB sean ideales para los fines de esta aplicación, ya que los MD poseen una naturaleza estocástica; pueden manifestarse simultáneamente en un álabe (no mutuamente excluyentes); interactuar (comportamientos condicionalmente dependientes); pueden tratarse como mecanismos no observables directamente que producen efectos observables como los MF; y en las inspecciones visuales, los especialistas deben manejar aspectos desconocidos o inciertos (p. ej., no se está seguro de si cierto MD está presente o no) que podrían ser muy limitantes para otros tipos de modelos.

Weber *et al.* [46] ofrecen un amplio compendio de aplicaciones de las RB en análisis de confiabilidad, riesgo y mantenimiento, mostrando una tendencia creciente en su uso, mientras que Kabir *et al.* [47] llegan a conclusiones similares en su revisión bibliográfica. Se ha demostrado que la capacidad de las RB para realizar inferencias o actualizar la evidencia en cualquier dirección es útil para el diagnóstico de fallos y análisis de confiabilidad de sistemas de ingeniería bajo variables con incertidumbre, como se constata en las revisiones bibliográficas de Cai *et al.* [48], [49], y los modelos propuestos por Chen *et al.* [50], aplicados a un tren de alta velocidad y un subsistema de un láser de estado sólido de alta potencia. Estas son características deseables para identificar MD responsables en los fallos de álabes.

Las RB se han utilizado para modelar sistemas complejos con componentes que interactúan y que pueden no ser fácilmente observados o inspeccionados. Los ejemplos

incluyen el diagnóstico de fallos de automóviles [51], la optimización del mantenimiento en centrales térmicas [52] y la simulación de accidentes para predecir su evolución en un reactor rápido de sodio [53]. El enfoque causal se utiliza ampliamente en los estudios de interacciones humano-sistema para manejar los factores que influyen en el rendimiento y que afectan la confiabilidad humana [54]–[56]. Los gasoductos se han estudiado desde la perspectiva de sus MD, para estimar las tasas de fallos [57], [58]. Se han evaluado las fallas de la red de agua para identificar las tuberías sensibles y tomar medidas de mantenimiento [59].

En cuanto a las turbinas en generación de energía, se han encontrado pocas investigaciones que involucren RB, y una parte de ellas son para turbinas de gas, sin embargo, se mencionan aquí a pesar de que sus MD son diferentes a los de las turbinas de vapor. Karlsson *et al.* [60] desarrollan una RB que se alimenta con la clasificación de una red neuronal de los tipos de fallo de los componentes del ciclo de la turbina a partir de sus parámetros de trabajo. Con este método se mejora la identificación de la causa raíz del fallo cuando el operador inserta observaciones de los parámetros de los sistemas. Sýkora *et al.* [61] confeccionaron una RB para evaluar las posibles interrupciones de operación de una central eléctrica de combustible fósil y sus consecuencias económicas y sociales, concluyendo que el sistema de presión de la caldera, la turbina de vapor y el generador son los más importantes para el riesgo económico, mientras que la turbina de vapor y las tuberías contribuyen al riesgo social. Dongiovanni *et al.* [62] aplicaron RB para evaluar las variaciones de la tasa de los modos de fallo para los componentes de una turbina de vapor nuclear cuando estos aumentan debido al funcionamiento en modo de pulso, de especial interés para investigaciones en los próximos reactores de fusión. Mirhosseini *et al.* [63] desarrollaron una metodología basada en RB para diagnosticar modos y mecanismos de fallos críticos en el lado caliente de la trayectoria del gas en turbinas para la generación de energía, utilizando datos históricos disponibles, juicio de expertos y el modelo *Noisy OR*. Hu *et al.* [64] desarrollaron un modelo dinámico de pronóstico basado en RB para la seguridad de sistemas industriales. Fue aplicado a un sistema de compresor y turbina de gas, permitiendo calcular la confiabilidad de los componentes con estados degradados. De los mencionados estudios en este párrafo, los enfoques se basan en tratar la turbina

como un super componente con diferentes tipos de fallos, o la turbina se subdivide en componentes explícitos, cada uno con diferentes tipos de fallos o MD, pero los álabes se modelan como un grupo completo.

2.2. Métodos de cuantificación de las redes bayesianas

Una de las limitantes de mayor peso de las redes bayesianas es su cuantificación. La cuantificación de estos modelos requiere especificar distribuciones de probabilidad condicional para completar las TPC. El número de valores que se deben ingresar en una TPC aumenta exponencialmente a medida que aumenta el número de nodos padres de un nodo hijo. Existen varias formas de obtener dichos valores, por ejemplo, a partir de la estadística de cuántas veces un fenómeno independiente da lugar a uno dependiente. En el informe [65, p. 96], Cain recomienda que deben tenerse al menos 20 casos por cada combinación de estados de los padres sobre un nodo hijo, si no, se debe tratar otro método para obtener dicha información.

El problema de la escasez de datos puede darse por varias razones, por ejemplo, los modelos desarrollados se encuentran en la frontera del conocimiento y no existen datos anteriores, o los datos existentes son muy escasos debido a que los eventos son de muy baja frecuencia. En la ingeniería de la confiabilidad, esta escasez es común en el modelado de sistemas muy confiables (p. ej., nucleares, aeroespaciales) o eventos raros, sistemas con diseños novedosos de los cuales no se tiene registro, o simplemente debido a que, en muchas ocasiones, los registros de fallos son confidenciales. En el caso que concierne a esta investigación, la turbina de vapor, específicamente las instaladas en plantas nucleares poseen un grado de confidencialidad que dificulta la obtención de datos estadísticos para el cálculo de las probabilidades pertinentes. Aunado a ello, el elevado grado de resolución que pretende el modelo (relaciones entre MD y con las ubicaciones de los álabes dentro de la turbina) es un reto si se tiene en cuenta que sería necesaria una estadística de fallos suficientemente sólida para cada combinación de filas y partes de álabes, la cual no existe. Más adelante, en el Capítulo IV se verá que es necesario definir una TPC con 288 combinaciones para una turbina con 9 filas de álabes.

En las mencionadas situaciones, el conocimiento experto puede ser utilizado para suplementar la falta de información y es el enfoque utilizado en esta investigación para lidiar con la escasez de datos.

Lidiando con este mismo problema, otros autores han desarrollado métodos automáticos de cálculo de probabilidades locales. Mediante estos métodos se calculan los valores desconocidos correspondientes a combinaciones de una TPC a partir de datos conocidos que se encuestan a los expertos en un tema específico, o que se obtienen por otras vías. A continuación, se realiza una revisión bibliográfica de estos métodos con el propósito de definir uno que sea compatible con las características deseadas para la RB que contiene los MD de los álabes de una turbina de vapor.

Uno de los métodos más simples es la interpolación de los valores de la TPC desconocidos a partir de valores probabilísticos encuestados correspondientes a ciertas combinaciones de los padres. Tang & McCabe [66] llevaron a cabo un estudio en donde interpolan los valores faltantes de una TPC, comparando los resultados de las interpolaciones lineales simples y por partes con la TPC real obtenida directamente de una encuesta a expertos en el tema de construcción aeroportuaria. El estudio mostró mejores resultados para la interpolación lineal por partes.

Cain [65] desarrolló un método basado en factores de interpolación. Los factores se calcularon como el cociente entre el cambio de probabilidad causado por un nodo padre cuando este varía de un estado favorable a uno no favorable, y el cambio causado por todos los nodos padre cambiando sus estados de la misma manera. Los factores de interpolación se utilizan para determinar las probabilidades faltantes a partir de las conocidas.

El método EBBN de Wisse *et al.* [67] se basa en factores de influencia de los estados de los padres hacia los nodos hijos que cuantifican la tendencia del nodo hijo a su estado más favorable (por ejemplo, éxito) cuando sus padres tienen esta misma tendencia, o viceversa. Los factores de influencia se utilizan en combinación con interpolaciones lineales y pesos para determinar el TPC.

Partiendo del supuesto de que cuanto mayor sea la diferencia cualitativa entre los estados de los nodos padre respecto al hijo, menor será el valor que debe asignarse a esa probabilidad condicional, Røed *et al.* [68] propusieron un método de cálculo de TPC. La diferencia mencionada, llamada distancia, se combina con factores de importancia ponderada de cada padre para determinar una medida de distancia ponderada. Luego, la distribución del nodo hijo se calcula mediante una función exponencial con la distancia ponderada como parámetro.

Chin *et al.* [69] utilizaron el juicio de comparación por pares (*pair-wise comparison*) entre estados para generar las distribuciones de nodos tipo raíz (un nodo sin padres) y nodos hijos con un sólo padre. Para el caso del nodo condicionado por un solo padre, la comparación por pares se repite tantas veces como estados tenga el padre. Para los nodos con dos o más padres, el procedimiento seguido para el caso de un solo padre se repite para cada uno, y luego la TPC completa del nodo hijo se normaliza.

Las variables lingüísticas suelen ser más familiares para los expertos y más fáciles de encuestar. Liu *et al.* [70] usaron lógica difusa para transformar estimaciones lingüísticas (p. ej., muy alto, alto, bajo, muy bajo) en probabilidades mediante la asignación de distribuciones a los estados lingüísticos, luego se utiliza un conjunto de reglas lógicas del tipo “si condición, entonces” (*if-then*) para controlar la salida del sistema de inferencia difusa y las probabilidades condicionales son las resultado de estas reglas lógicas.

Fenton *et al.* [71] desarrollaron el método de nodos clasificados (*ranked nodes*). Utiliza distribuciones probabilísticas continuas como funciones de ponderación para los nodos padres, que luego se discretizan en intervalos discretos, lo que permite la determinación de grandes TPC. Mejoras al método y ejemplos de aplicaciones se han estudiado en [72], [73].

Recopilaciones de diferentes métodos para el cálculo de las TPC se encuentran disponibles, como por ejemplo los trabajos de Mkrтчhyan *et al.* [74], [75], que ofrecen un análisis de varios métodos para su aplicación en la estimación de la confiabilidad humana (*human reliability analysis: HRA*). Zang y Thai [76] presentan una discusión sobre elicitación de expertos desde la perspectiva de los accidentes marítimos y Warner *et al.*

[77] analizan el juicio de expertos para estimar dependencias para su uso en modelos probabilísticos.

Los métodos analizados utilizan, en mayor o menor medida, una serie de parámetros intermedios necesarios para procesar la información obtenida de los expertos y producir probabilidades condicionales faltantes. Por ejemplo, implican normalizaciones, cálculo de factores de peso, interpolaciones y factores de influencia, u otras definiciones específicas según la aplicación. Es por esto que existe una preferencia hacia los llamados modelos canónicos [78], o “unidades elementales utilizadas en la construcción de modelos más complicados” (frase original en inglés [79]), por lo que requieren menos parámetros intermedios necesarios para calcular las probabilidades de salida de la TPC y su aplicación a diferentes contextos requiere menor esfuerzo.

En este grupo se incluye la conocida puerta lógica *Noisy* OR (N-OR). El N-OR [80] es una generalización ampliamente utilizada de la puerta determinista OR, donde las variables independientes (nodos padre) pueden lograr un efecto (nodo hijo) con una probabilidad diferente de 1. El *Noisy* MAX [81], [82] es una generalización del N-OR donde las variables modeladas no están restringidas a ser binarias.

Los modelos *Non-impeding Noisy AND Trees* (NAT) permiten modelar causas cuya probabilidad conjunta es mayor que sus probabilidades independientes, como los modelos N-OR, así como causas cuya probabilidad conjunta es menor que sus probabilidades independientes, como los N-AND [83]. Sin embargo, una compuerta N-AND es igual a cero si tan sólo una de las señales de entrada (causas) es cero, pero en el NAT, esta situación se relaja, por lo que, si una causa está ausente, el resultado no es cero, basándose sólo en las restantes causas presentes. Es posible también considerar causas y efectos con múltiples estados ordenados [84], siendo una generalización del modelo *Noisy* MAX [85]. Cuando algunos subconjuntos de causas se inhiben y otros se refuerzan, el orden en el que éstas se consideran para construir la topología del modelo influye en gran medida en los resultados, por lo que han sido propuestos métodos para determinar la topología correcta que describa mejor los datos disponibles [86], [87].

Se han propuesto otras generalizaciones del modelo N-OR que consideran, además, la incertidumbre de los parámetros [88], [89]. Recomendables trabajos como los de Diez y Druzdzel [79] y el de Zagorecki [90] ofrecen resúmenes de la evolución de los modelos canónicos para el cálculo de las probabilidades puntuales que conforman las TPC.

Estos modelos canónicos consideran que la probabilidad de que cada variable modelada cause el efecto, es independiente del conjunto restante de variables que pueden causar el mismo efecto, por lo que su influencia conjunta se rige por el modelo N-OR. La referida independencia se denomina formalmente independencia de influencia causal [79], [90], [91]. Por sus siglas en inglés, se abrevia como ICI, de *independence of causal influence*.

Para superar esta limitación y considerar las complejas influencias de los MD, el modelo *Recursive Noisy OR* (RNOR), desarrollado por Lemmer y Gossink [92] maneja conceptos como sinergia e interferencia. La sinergia es cuando la probabilidad conjunta calculada a partir de las probabilidades independientes de algunos factores, variables o causas que influyen en la obtención de un efecto, es mayor que cuando se utiliza el N-OR, o lo que es lo mismo, la condición ICI. Por el contrario, la interferencia se produce cuando la probabilidad conjunta de dichos factores es menor que el calculado mediante el N-OR. Note que N-OR marca el límite entre la sinergia y la interferencia porque aplica la condición ICI. Sin embargo, la interferencia se considera siempre que se mantenga la causalidad positiva. La causalidad positiva implica que agregar causas adicionales nunca disminuye la probabilidad conjunta de obtener el efecto. Los valores de probabilidad conjunta que caen por debajo de la causalidad positiva producen rangos incorrectos en las probabilidades calculadas por el RNOR y deben evitarse, lo cual constituye la principal limitación de este modelo.

Los autores de los modelos NAT sostienen que sus resultados son probabilidades conjuntas sinérgicas [86], pero lo hacen bajo una definición diferente dada por Chang *et al.* [93], donde la sinergia comprende todo el rango de causalidad positiva previamente definido por Lemmer y Gossink [92]. Así, al igual que los modelos N-OR, los NAT son ICI, por lo que no se considera la sinergia de la misma manera que en el RNOR. La sinergia del RNOR expande la aplicabilidad del modelado para incluir fenómenos con

causas que son cuestionablemente independientes y, de esta manera, relajar la condición de ICI.

Debido al enfoque causal que poseen los modelos anteriores, existe la posibilidad de que, para un evento, no sea posible conocer todas las posibles causas que lo provocan. Las RB, como cualquier modelo, representan una aproximación de la realidad y parte del conocimiento de las variables que intervienen en el fenómeno estudiado. Como tal, existen variables que consciente o inconscientemente son excluidas de los modelos. Ante esta problemática, la no modelación de potenciales variables que pueden influenciar las variables explícitamente consideradas en el modelo, Henrion [94] postuló un parámetro llamado “*leak*” o fuga en español, representando la posibilidad de ocurrencia de una variable dependiente cuando las causas explícitamente modeladas en la red se encuentran en estado ausente. El *leak*, engloba ese desconocimiento, o variables no consideradas en el modelo, que influyen la obtención de un efecto.

$$1 - COM_i = (1 - NET_i) * (1 - Leak) \quad (4)$$

El parámetro *leak* es combinado con los parámetros netos (NET_i) para determinar los parámetros compuestos (COM_i), según la expresión (4). Los parámetros compuestos son los que finalmente, componen la TPC. Una discusión detallada de la diferencia de ambos tipos de parámetros (netos y compuestos) puede encontrarse en [79, Sec. 4.2.1], así como propuestas de los tipos de preguntas que se pueden formular para encuestar cada tipo de parámetro a los expertos.

2.3. Resumen y conclusiones parciales: redes bayesianas y cuantificación

En el presente capítulo se han presentado los fundamentos matemáticos de las RB, las cuales pueden manejar gran número de probabilidades condicionales y de variables aleatorias, constituyendo una herramienta formal y bien establecida para realizar razonamientos a partir de la evidencia disponible, propagando la evidencia en cualquier dirección de la estructura de la red. Sus potencialidades se han popularizado en un sinnúmero de campos, especialmente en la ingeniería de la confiabilidad. También se han analizado numerosas referencias que tratan el tema de la cuantificación de las RB. De los anteriormente expuesto se extraen las siguientes conclusiones:

1. Las RB son una solución factible para construir un modelo que considere las dependencias probabilísticas que se dan entre los MD de un componente, además de las dependencias con su ubicación.
2. Una gran cantidad de datos son requeridos para cuantificar las TPC de las RB, lo cual es una limitación, sin embargo, existen métodos automáticos para el cálculo de estos valores a partir de una cantidad razonable de valores conocidos.
3. Debido a que el modelo a construir en esta investigación requiere de gran cantidad de datos, y al nivel de resolución que se desea obtener, la obtención directa mediante estadística de los datos requeridos para cuantificar el modelo no se encuentra disponible. Se requiere de la encuesta a expertos para dar solución a esta limitación.
4. De entre los métodos consultados para el cálculo de las TPC, el RNOR ofrece ventajas: no está restringido por la condición ICI, favoreciendo la flexibilidad para contemplar las probabilidades conjuntas de influencia de los MD; es relativamente simple respecto a los modelos no canónicos, en los que intervienen gran número de cálculos intermedios; se puede combinar con el parámetro *leak*, para considerar la posibilidad de que un MD se produzca sin la presencia de otros MD que lo influencien directamente.

Capítulo III: Recursive Noisy OR Extendido

En el capítulo anterior fueron analizados varios métodos para el cálculo automático de probabilidades puntuales, útiles para determinar TPC en RB. Recordando la factibilidad del uso de las RB para crear una herramienta que contemple las probabilidades condicionales que existen entre los MD, su dependencia con la ubicación de los álabes dentro de turbina de vapor, y la escasez de datos por las razones ya analizadas, se concluyó en el Capítulo II que el modelo RNOR propuesto por Lemmer y Gossink [92] posee características factibles para determinar las influencias que unos MD poseen sobre otros.

Recordando que la intención es primeramente crear un modelo estático (independiente del tiempo), de razonablemente fácil manipulación y cuantificación por parte de los especialistas en mantenimiento de turbina, y un modelo dinámico más complejo en donde las variables dependen del tiempo, el modelo RNOR debe ser analizado para comprobar su factibilidad en manejar la variable temporal. Desde luego, si el RNOR quiere ser utilizado para calcular valores puntuales en TPC en el primer modelo y funciones continuas dependientes del tiempo en el segundo modelo, ambas versiones deben proveer resultados iguales cuando son evaluadas en un punto. Al RNOR dinámico se le llamaría DRNOR y permitiría obtener una función continua de la influencia de las causas, dependientes de una variable temporal, aprovechando las ventajas que ofrece este modelo para manejar sinergias.

Durante el proceso de comprobación, problemas surgieron, dando por resultado que otro modelo derivado del RNOR tomara su lugar, corrigiendo un problema conocido como asimetría. El problema de la asimetría ha sido señalado en los trabajos de Díez y Druzdzel [79] y de Woudenberg *et al.* [95], argumentando que el orden en que las causas o variables son consideradas, cuando estas son más de tres, afecta el resultado de la probabilidad conjunta, lo cual carece de fundamento lógico. Al nuevo modelo, que puede generar probabilidades puntuales (independientes del tiempo) y continuas (considerando el tiempo), se le bautizó como ERNOR (E por extendido).

El ERNOR, en su versión estática, es un modelo útil para calcular valores desconocidos de una TPC a partir del conocimiento de probabilidades de causas unitarias (CU) y conjuntas. En su versión dinámica, resulta en una función de distribución acumulada dependiente del tiempo, a partir de las influencias conjuntas de varias causas, también dependientes del tiempo. Ambas versiones pueden manejar sinergia y se demuestra que son equivalentes.

Con esta motivación, y antes de pasar al desarrollo y cuantificación de la RB en el Capítulo IV, en el presente capítulo se presenta el desarrollo del modelo ERNOR en sus dos versiones. Se sigue un enfoque cronológico, por lo que se comienza explicando brevemente los fundamentos del original RNOR, luego el intento de desarrollo del DRNOR para establecer el contexto, y posteriormente los análisis que conllevaron a que el autor descontinuara su uso y desarrollara el ERNOR. Luego se presentan resultados cuantitativos del nuevo modelo y cómo éste es efectivamente una versión más completa de su predecesor.

3.1. El modelo Recursive Noisy OR

Este modelo fue propuesto por Lemmer y Gossink [92] en 1994 como una alternativa a los modelos ICI. Aunque no es obligatorio, el RNOR se explica fácilmente adoptando un enfoque causal, por lo que las explicaciones subsecuentes tienen este enfoque. Sin embargo, algunos lectores pueden extrapolar fácilmente las causas ausentes/presentes a señales ausentes/presentes que desencadenan una señal de salida (el efecto) con una probabilidad diferente a uno. El RNOR se basa en que la probabilidad de que algunas causas logren un efecto podría ser diferente al resultado obtenido al aplicar el modelo N-OR, donde los efectos de las CU se combinan asumiendo independencia. Matemáticamente, esta diferencia es $P_X \neq \prod_{i=1}^{n-1} (1 - P_{x_i})$, donde X es el conjunto de causas x_1, \dots, x_{n-1} ; P_{x_i} es la probabilidad de que x_i logre el efecto por sí sola, y P_X es el efecto probabilístico total de las $n - 1$ causas que actúan simultáneamente, o probabilidad conjunta de las $n - 1$ causas.

Si P_X se conoce *a priori*, por ejemplo, porque un experto estima el valor y se denota P_X^E (el superíndice E por experto), y luego se considera otra causa adicional x_n , cuya

probabilidad de provocar el efecto se sabe que es independiente de la probabilidad conjunta de las causas del conjunto original X , así como de cualquier subconjunto de causas de X ; la probabilidad conjunta de esta unión es $P_{X \cup x_n} = (1 - P_X^E)(1 - P_{x_n}) \forall P_X^E \neq \prod_{i=1}^{n-1}(1 - P_{x_i})$.

Si el caso fuera $P_X^E = \prod_{i=1}^{n-1}(1 - P_{x_i})$, que es el modelo N-OR, entonces la unión $X \cup x_n$ se simplifica a $P_{X \cup x_n} = \prod_{i=1}^n(1 - P_{x_i})$.

Ahora, suponga que la probabilidad de provocar el efecto que tiene la última causa agregada x_n no es independiente de la probabilidad conjunta del conjunto original de causas $X = \{x_1, \dots, x_{n-1}\}$ cuando se combinan, o de algún subconjunto de X . Para evaluar este tipo de interacción se propuso el modelo RNOR [92].

$$P_X^{RNOR} = \begin{cases} P_X^E & \text{si el experto provee esta información} \\ 1 - \prod_{i=0}^{n-1} \frac{(1 - P_{X \setminus \{x_i\}}^{RNOR})}{(1 - P_{X_i \setminus \{x_i, x_{(i+1) \bmod (n)}\}}^{RNOR})} & \text{si no} \end{cases} \quad (5)$$

En la expresión (5), las probabilidades de ciertas combinaciones de causas pertenecientes al conjunto X pueden ser proporcionadas por el experto P_X^E o calculadas por la ecuación recursiva que usa los valores de probabilidad de las combinaciones de causas de orden inferior. El símbolo " \setminus " denota la resta de conjuntos y "mod" es la función de módulo, por lo que el contador i se desfasa para comenzar en 0. RNOR usa conjuntos de causas unitarias como base para la recursividad, es decir, la probabilidad de que una sola causa x_i provoque el efecto. Si solo se conocen estos valores, entonces (5) es equivalente al N-OR. Sin embargo, si las probabilidades conjuntas correspondientes a combinaciones de segundo orden (conjuntos de causas tomadas dos a dos) difieren del modelo N-OR, entonces las probabilidades calculadas mediante (5) para el tercer orden y posteriores también serán diferentes.

Recapitulando, la sinergia se considera cuando la probabilidad conjunta de obtener un efecto dado un conjunto de causas es mayor que la probabilidad calculada por el modelo N-OR y la interferencia es lo opuesto, mientras que la causalidad positiva se cumpla. La

causalidad positiva es la condición de que cada causa adicional agregada a un conjunto X de causas no disminuya la probabilidad conjunta de lograr el efecto. El valor puntual obtenido mediante el modelo N-OR denota la condición ICI, por lo que no existe sinergia ni interferencia. Una desventaja de este modelo es que la violación de la causalidad positiva conduce a valores probabilísticos calculados ilógicos. Se recomienda al lector el estudio de la referencia [92], donde originalmente se propuso el RNOR. Otro problema potencial es cuando las probabilidades de los expertos son iguales a 1, lo cual hace que la expresión (5) se indefina porque un denominador es igual a cero. Los inconvenientes anteriores implican que sea necesario monitorear los resultados de la fórmula recursiva e imponer restricciones en el procedimiento de encuesta que se utilice para obtener la opinión experta.

3.2. RNOR Dinámico

Como ha sido mencionado, los valores calculados usando la ecuación RNOR son puntuales e independientes del tiempo. La idea para hacer la ecuación (5) dinámica es desarrollar expresiones dentro de su estructura que permitan la incorporación de funciones continuas de las causas que representen el nivel de presencia de éstas. La presencia es una función de distribución acumulada (FDA) de probabilidad para cada causa x_i , es decir $0 \leq F_i(t) \leq 1$ y se cumple que $F(t) = \int_0^t f(u)du$, donde $f(*)$ denota la función de densidad de probabilidad (FDP). Su complemento es $R(t) = 1 - F(t)$, o la probabilidad acumulada de que la causa no esté presente en un momento dado. La Figura 2 representa el concepto.




Figura 2: Influencias dinámicas de las causas

El modelo DRNOR, para que sea consecuente con el RNOR, debe cumplir con las tres condiciones siguientes (6), (7) y (8), las cuales se denominan aquí, axiomas de reducción (AR)

$$\forall F_{x_i}(t_i \rightarrow \infty) = 1 [i = 0,1, \dots, n - 1] \xrightarrow{\text{se cumple}} P_X^{DRNOR}(\infty) = P_X^{RNOR} \quad (6)$$

$$\begin{aligned} &\forall F_{x_i}(t_i \rightarrow \infty), F_{x_m}(0) = 0 [i = 0,1, \dots, n - 1; m \in X; m \neq i] \\ &\xrightarrow{\text{se cumple}} P^{DRNOR}(t_0, \dots, t_m = 0, \dots, t_{n-1}) = P_{X \setminus \{x_m\}}^{DRNOR}(t_0, t_1, \dots, t_{n-1}) = P_{x_1, \dots, \neg x_m, \dots, x_{n-1}}^{RNOR} = \\ &P_{X \setminus \{x_m\}}^{RNOR} \end{aligned} \quad (7)$$

$$\forall F_{x_i}(0) = 0 [i = 0,1, \dots, n - 1] \xrightarrow{\text{se cumple}} P_X^{DRNOR}(0) = P_{\neg X}^{RNOR} = 0 \quad (8)$$

El AR (6) implica que el valor calculado mediante el DRNOR debe coincidir con el valor puntual RNOR cuando la probabilidad de que todas las causas estén presentes es uno (en funciones acumulativas esto ocurre en el infinito o puede considerarse presente para un tiempo razonablemente largo con un pequeño error). Esta proposición se fundamenta en el hecho de que el RNOR es un modelo que considera que las causas están presentes o ausentes, por lo que para que el modelo dinámico sea equivalente al estático, sus resultados tienen que ser iguales a medida que todas las funciones acumulativas de las causas se aproximan a la probabilidad 1 en un tiempo razonablemente largo. Por el contrario, si todas las causas están ausentes, la probabilidad de obtener el efecto es nulo, y este es el AR (8). En el caso intermedio se encuentra el AR (7), cuando la ecuación RNOR (DRNOR) se construye inicialmente para un conjunto X de causas, y una causa x_m se torna ausente (su función acumulativa es cero) mientras que las demás se mantienen presentes, entonces el resultado de ambos modelos coincide y es igual al resultado que se obtiene si el RNOR (DRNOR) se construyera desde un inicio omitiendo la causa x_m . En esta investigación, a la substracción de causas de un conjunto inicial se le llama reducción orden: un modelo causal (ya sea para probabilidades puntuales o continuas) que se construye considerando n causas presentes inicialmente, de las cuales p causas específicas se tornan ausentes eventualmente, tiene que dar el mismo resultado que un modelo que se construye desde un inicio para n menos las mismas p causas mencionadas.

Se comienza introduciendo el comportamiento dinámico de las CU y combinaciones de segundo orden. Las expresiones (9) y (10) son transformaciones (TR) que convierten las expresiones estáticas en dinámicas.

$$P_{x_i}^E := P_{x_i}^E(t) = P_{x_i}^E * F_{x_i}(t) \quad (9)$$

$$P_{x_a, x_b}^E := P_{x_a, x_b}^E(t) = P_{x_a}^E * F_{x_a}(t) * R_{x_b}(t) + P_{x_b}^E * R_{x_a}(t) * F_{x_b}(t) + P_{x_a, x_b}^E * F_{x_a}(t) * F_{x_b}(t) \quad \text{con } x_a, x_b \in X; a \neq b \quad (10)$$

La TR (9) significa que la probabilidad independiente de una causa x_i en provocar un efecto, proporcionada por el experto (valor puntual en el RNOR), se transforma en dinámica mediante su descomposición en su propia constante, multiplicada por la FDA de esa causa. Lo anterior implica que cuando la causa está completamente presente ($F_{x_i}(t = \infty) = 1$), se logra la influencia máxima, y no hay influencia cuando la causa está ausente ($F_{x_i}(t = 0) = 0$), por lo tanto, la TR (9) cumple con los AR (6) a (8) para una sola causa.

La TR (10) proviene de la aplicación del teorema de probabilidad total a un nodo binario con dos padres binarios, cuyos estados son R (ausente) y F (presente). La TR (10) cumple con el AR (6) para dos causas si ambas están presentes, esto es: $F_{x_a}(t \rightarrow \infty) = 1$, $R_{x_a}(t \rightarrow \infty) = 0$, $F_{x_b}(t \rightarrow \infty) = 1$, $R_{x_b}(t \rightarrow \infty) = 0$; luego, sustituyendo en (10) se obtiene $P_{x_a, x_b}^E(t_{a,b} \rightarrow \infty) = P_{x_a, x_b}^E$ y las probabilidades conjuntas de los modelos dinámico y estático coinciden. Mediante los mismos razonamientos, estableciendo las dos causas como ausentes se tiene que $F_{x_a}(t = 0) = F_{x_b}(t = 0) = 0$ y todos los términos de la expresión (10) son nulos, por lo que $P_{x_a, x_b}^E(t_{a,b} = 0) = P_{\neg x_a, \neg x_b}^E = 0$, y la TR (10) cumple con el AR (8). Finalmente, para probar que la TR (10) cumple con el AR (7), se establece una sola causa como ausente, por ejemplo, x_a . La proposición implica $F_{x_a}(t = 0) = 0$, $R_{x_a}(t = 0) = 1$, $F_{x_b}(t \rightarrow \infty) = 1$, $R_{x_b}(t \rightarrow \infty) = 0$, y sustituyendo en (10), se obtiene $P_{x_a, x_b}^E(t_a = 0, t_b \rightarrow \infty) = P_{x_b}^E$. Los análisis anteriores prueban que la TR (10) cumple con los tres AR y acepta una reducción de orden de dos causas a una sola y al caso donde las causas son nulas.

La ecuación desarrollada del RNOR para tres causas es

$$P_{x_0, x_1, x_2}^{RNOR} = 1 - \frac{(1-P_{x_0, x_1}^E)(1-P_{x_0, x_2}^E)(1-P_{x_1, x_2}^E)}{(1-P_{x_0}^E)(1-P_{x_1}^E)(1-P_{x_2}^E)} \quad (11)$$

y sustituyendo (9) y (10) en (11) con los subíndices correctos, se obtiene el DRNOR para tres causas

$$P_{x_0, x_1, x_2}^{RNOR}(t) = 1 - \frac{(1-P_{x_0, x_1}^E(t))(1-P_{x_0, x_2}^E(t))(1-P_{x_1, x_2}^E(t))}{(1-P_{x_0}^E(t))(1-P_{x_1}^E(t))(1-P_{x_2}^E(t))} \quad (12)$$

donde

$$\begin{aligned} P_{x_0, x_1}^E(t) &= P_{x_0}^E * F_{x_0}(t) * R_{x_1}(t) + P_{x_1}^E * R_{x_0}(t) * F_{x_1}(t) + P_{x_0, x_1}^E * F_{x_0}(t) * F_{x_1}(t) \\ P_{x_0, x_2}^E(t) &= P_{x_0}^E * F_{x_0}(t) * R_{x_2}(t) + P_{x_2}^E * R_{x_0}(t) * F_{x_2}(t) + P_{x_0, x_2}^E * F_{x_0}(t) * F_{x_2}(t) \\ P_{x_1, x_2}^E(t) &= P_{x_1}^E * F_{x_1}(t) * R_{x_2}(t) + P_{x_2}^E * R_{x_1}(t) * F_{x_2}(t) + P_{x_1, x_2}^E * F_{x_1}(t) * F_{x_2}(t) \\ P_{x_0}^E(t) &= P_{x_0}^E * F_{x_0}(t); P_{x_1}^E(t) = P_{x_1}^E * F_{x_1}(t); P_{x_2}^E(t) = P_{x_2}^E * F_{x_2}(t) \end{aligned} \quad (13)$$

3.3. Análisis de reducción del DRNOR

Se puede verificar que la expresión (12), construida por tres causas (orden 3), se reduce efectivamente a la forma de la expresión de segundo orden (10), si alguna de las tres causas está ausente (su tiempo se restablece a cero). Para probarlo, asuma que, en un momento arbitrario, x_2 se torna ausente. Por la demostración de que la TR (10) cumple con los AR (6), (7) y (8), y estableciendo $F_{x_2}(t = 0) = 0$, la expresión (12) resulta en

$$P_{x_0, x_1, x_2}^{RNOR}(t_2 = 0) = 1 - \frac{(1-P_{x_0, x_1}^E(t))(1-P_{x_0}^E(t))(1-P_{x_1}^E(t))}{(1-P_{x_0}^E(t))(1-P_{x_1}^E(t))} = 1 - (1 - P_{x_0, x_1}^E(t)) = P_{x_0, x_1}^E(t) \quad (14)$$

Si dos causas están ausentes, entonces la expresión (12) se simplifica a la forma de (9) y si las tres causas están ausentes, el resultado es cero. Esto demuestra que, al menos hasta el tercer orden, el DRNOR es equivalente a las expresiones de orden inferior cuando algunas causas están ausentes y es consistente con los AR.

La expresión para el cuarto orden se presenta a continuación.

$$1 - P_{x_0, x_1, x_2, x_3}^{DRNOR}(t) = \frac{(1 - P_{x_1, x_2, x_3}^{DRNOR}(t))(1 - P_{x_0, x_2, x_3}^{DRNOR}(t))(1 - P_{x_0, x_1, x_3}^{DRNOR}(t))(1 - P_{x_0, x_1, x_2}^{DRNOR}(t))}{(1 - P_{x_2, x_3}^E(t))(1 - P_{x_0, x_3}^E(t))(1 - P_{x_0, x_1}^E(t))(1 - P_{x_1, x_2}^E(t))} \quad (15)$$

Ahora, asuma que $F_{x_0}(0) = 0$, lo que implica el conjunto de reducciones (16) en los factores de (15).

$$P_{\neg x_0, x_2, x_3}^{DRNOR}(t) = P_{x_2, x_3}^E(t); P_{\neg x_0, x_1, x_3}^{DRNOR}(t) = P_{x_1, x_3}^E(t); P_{\neg x_0, x_1, x_2}^{DRNOR}(t) = P_{x_1, x_2}^E(t)$$

$$P_{\neg x_0, x_3}^E(t) = P_{x_3}^E(t); P_{\neg x_0, x_1}^E(t) = P_{x_1}^E(t) \quad (16)$$

Las reducciones anteriores son de 3er orden al 2do, y de 2do a CU, que ya se ha demostrado que son consistentes con los AR en el último párrafo. Siendo así, se espera que la igualdad (17) sea verdadera para satisfacer el AR (7), esto es:

$$P_{\neg x_0, x_1, x_2, x_3}^{DRNOR}(t) = P_{x_1, x_2, x_3}^{DRNOR}(t) \quad (17)$$

Sustituyendo (16) y (17) en (15) se obtiene la expresión intermedia

$$1 - P_{\neg x_0, x_1, x_2, x_3}^{DRNOR}(t) = 1 - P_{x_1, x_2, x_3}^{DRNOR}(t) = \frac{(1 - P_{x_1, x_2, x_3}^{DRNOR}(t))(1 - P_{x_2, x_3}^E(t))(1 - P_{x_1, x_3}^E(t))(1 - P_{x_1, x_2}^E(t))}{(1 - P_{x_2, x_3}^E(t))(1 - P_{x_3}^E(t))(1 - P_{x_1}^E(t))(1 - P_{x_1, x_2}^E(t))}$$

Cancelando términos y arreglando se obtiene

$$1 - P_{x_1, x_2, x_3}^{DRNOR}(t) = \frac{(1 - P_{x_1, x_3}^E(t))}{(1 - P_{x_1}^E(t))(1 - P_{x_3}^E(t))} * (1 - P_{x_1, x_2, x_3}^{DRNOR}(t)) \text{ si } F_{x_0}(0) = 0 \quad (18)$$

De forma similar, haciendo cero la presencia de las demás causas, una a la vez, la expresión (15) se reduce a las formas siguientes:

$$1 - P_{x_0, x_2, x_3}^{DRNOR}(t) = \frac{(1 - P_{x_0, x_2}^E(t))}{(1 - P_{x_0}^E(t))(1 - P_{x_2}^E(t))} * (1 - P_{x_0, x_2, x_3}^{DRNOR}(t)) \text{ si } F_{x_1}(0) = 0 \quad (19)$$

$$1 - P_{x_1, x_2, x_3}^{DRNOR}(t) = \frac{(1 - P_{x_1, x_3}^E(t))}{(1 - P_{x_1}^E(t))(1 - P_{x_3}^E(t))} * (1 - P_{x_1, x_2, x_3}^{DRNOR}(t)) \text{ si } F_{x_2}(0) = 0 \quad (20)$$

$$1 - P_{x_0, x_1, x_2}^{DRNOR}(t) = \frac{(1 - P_{x_0, x_2}^E(t))}{(1 - P_{x_0}^E(t))(1 - P_{x_2}^E(t))} * (1 - P_{x_0, x_1, x_2}^{DRNOR}(t)) \text{ si } F_{x_3}(0) = 0 \quad (21)$$

Note que cada ecuación desde (18) hasta (21) es una igualdad sólo cuando el cociente de cada miembro derecho es uno. Por ejemplo, para que (18) sea una igualdad y (17)

sea verdadera, es necesario que $(1 - P_{x_1, x_3}^E(t)) = (1 - P_{x_1}^E(t))(1 - P_{x_3}^E(t))$, que es la expresión del modelo N-OR con la restricción ICI, una condición que contradice la esencia del RNOR. Por lo tanto, el conjunto de ecuaciones (18) a (21) nos permite concluir que el DRNOR no es correctamente reducible si la relación entre los CU y sus combinaciones de segundo orden no sigue un modelo N-OR. Tal conclusión es extensible para órdenes superiores a cuatro, donde otros factores contribuyen a la desigualdad. Aunque estas ecuaciones corresponden al DRNOR, el problema es el mismo para el caso independiente del tiempo, el RNOR.

La causa del problema se explica a continuación. En (15) todas las combinaciones posibles de tercer orden que se pueden formar con cuatro elementos están presentes en los numeradores, pero todas las combinaciones de segundo orden no están en los denominadores: las probabilidades de las combinaciones x_0, x_2 y x_1, x_3 no se encuentran explícitas y, por supuesto, ninguno de los CU está explícitamente representado en (15). Cuando (15) se reduce en un orden al establecer las causas como ausentes, una a la vez, todas las combinaciones que no estaban explícitas surgen en el conjunto de ecuaciones (18) a (21) y son, de hecho, la fuente del problema que enfrentan el RNOR y el DRNOR en el proceso de reducción.

A lo anterior se le llama asimetría, problema que se ha mencionado previamente en este trabajo, y también por otros autores [79] [95], indicando que el orden de los subíndices en (5) es relevante cuando se consideran cuatro o más causas. En este sentido, no sería lo mismo calcular P_{x_0, x_1, x_2, x_3} que P_{x_1, x_3, x_0, x_2} de acuerdo con el RNOR, y esto es un inconveniente sin justificación porque son, en esencia, las mismas causas generando probabilidades conjuntas diferentes. En esta investigación, como se demostró en la discusión anterior, se identifica otro inconveniente que resulta de este problema, y es que las ecuaciones construidas para combinaciones de orden superior (cuarto orden y más) siguiendo el modelo RNOR (y por ende el DRNOR) no son equivalentes a las ecuaciones de orden inferior cuando algunas causas se tornan ausentes. La equivalencia solo se mantiene hasta el 3er orden, que puede reducirse efectivamente a 2do y a CU, tornando el número correcto de causas a ausente.

3.4. RNOR Extendido

En esta sección se presenta una nueva versión extendida del RNOR (ERNOR). El nombre fue elegido ya que ambos modelos coinciden hasta el tercer orden, pero surgen diferencias estructurales en sus expresiones para el cuarto orden y superiores. Es aquí donde se elimina el problema de asimetría con el modelo ERNOR, lo que permite un comportamiento dinámico consistente cuando las causas toman niveles de presencia arbitrarios o están ausentes. Además, como se demostrará en la sección 3.5 la estructura del RNOR está contenida en el ERNOR. Resumiendo, la palabra extendido implica una modificación en la estructura del RNOR original que elimina el problema de la asimetría y el aporte de introducir las causas dinámicas mediante el uso de (9) y (10). De esta forma, el ERNOR puede calcular TPC en RB y con las TR (9) y (10), puede ser incorporado como compuerta lógica en modelos que no dependen de probabilidades puntuales, sino continuas, como por ejemplo, un AF.

Como se explica en la sección 3.3, el proceso de reducción de DRNOR da lugar a algunos factores inexistentes en la ecuación original para cuatro causas. Las probabilidades de combinaciones x_0, x_2 y x_1, x_3 faltan en el denominador de (15), pero están presentes en numeradores de (18) a (21) respectivamente. Además, todos los CU surgen en los denominadores de las formas reducidas (18) a (21). Siguiendo esa lógica, se observa que se necesitan algunos factores para mantener la simetría y lograr una reducción efectiva. Añadiendo los factores que faltan en (15) se obtiene la siguiente expresión:

$$\begin{aligned}
 1 - P_{x_0, x_1, x_2, x_3}^{ERNOR}(t) &= \left[\frac{(1 - P_{x_1, x_2, x_3}^{ERNOR}(t))(1 - P_{x_0, x_2, x_3}^{ERNOR}(t))(1 - P_{x_0, x_1, x_3}^{ERNOR}(t))(1 - P_{x_0, x_1, x_2}^{ERNOR}(t))}{(1 - P_{x_2, x_3}^E(t))(1 - P_{x_0, x_3}^E(t))(1 - P_{x_0, x_1}^E(t))(1 - P_{x_1, x_2}^E(t))} \right] \\
 & * \left[\frac{(1 - P_{x_0}^E(t))(1 - P_{x_1}^E(t))(1 - P_{x_2}^E(t))(1 - P_{x_3}^E(t))}{(1 - P_{x_0, x_2}^E(t))(1 - P_{x_1, x_3}^E(t))} \right] \quad (22)
 \end{aligned}$$

La ecuación (22) es la forma del nuevo modelo, el ERNOR por cuatro causas. El primer corchete contiene la forma clásica del RNOR (dinámico en este caso) para cuatro causas. Los superíndices se cambiaron para expresar que este modelo es el ERNOR. Para cinco causas x_0, x_1, x_2, x_3, x_4 , el ERNOR es

$$\begin{aligned}
 & 1 - P_{x_0, x_1, x_2, x_3, x_4}^{ERNOR} \\
 &= \left[\frac{(1 - P_{x_1, x_2, x_3, x_4}^{ERNOR})(1 - P_{x_0, x_2, x_3, x_4}^{ERNOR})(1 - P_{x_0, x_1, x_3, x_4}^{ERNOR})(1 - P_{x_0, x_1, x_2, x_4}^{ERNOR})(1 - P_{x_0, x_1, x_2, x_3}^{ERNOR})}{(1 - P_{x_2, x_3, x_4}^{ERNOR})(1 - P_{x_0, x_3, x_4}^{ERNOR})(1 - P_{x_0, x_1, x_4}^{ERNOR})(1 - P_{x_0, x_1, x_2}^{ERNOR})(1 - P_{x_1, x_2, x_3}^{ERNOR})} \right] \\
 & * \left[\frac{(1 - P_{x_0, x_1}^E)(1 - P_{x_0, x_2}^E)(1 - P_{x_1, x_2}^E)(1 - P_{x_0, x_3}^E)(1 - P_{x_1, x_3}^E)}{(1 - P_{x_0, x_2, x_3}^{ERNOR})(1 - P_{x_0, x_1, x_3}^{ERNOR})(1 - P_{x_1, x_2, x_4}^{ERNOR})(1 - P_{x_0, x_2, x_4}^{ERNOR})(1 - P_{x_1, x_3, x_4}^{ERNOR})} \right] \\
 & * \left[\frac{(1 - P_{x_2, x_3}^E)(1 - P_{x_0, x_4}^E)(1 - P_{x_1, x_4}^E)(1 - P_{x_2, x_4}^E)(1 - P_{x_3, x_4}^E)}{(1 - P_{x_0}^E)(1 - P_{x_1}^E)(1 - P_{x_2}^E)(1 - P_{x_3}^E)(1 - P_{x_4}^E)} \right] \tag{23}
 \end{aligned}$$

En (23) se omiten los tiempos, por lo que es una ecuación estática, sin embargo, lo mismo se aplica a la versión dinámica usando las TR (9) y (10). Nuevamente, el primer corchete es el RNOR y se puede inferir fácilmente que cuando se consideran más causas, la asimetría se vuelve más fuerte dada la cantidad de factores descartados del RNOR que ahora se consideran en el segundo y tercer corchetes del modelo ERNOR en (23). Se puede verificar que (23) se reduce a (22) si la causa x_4 se torna ausente. Además, tanto (23) como (22) se pueden reducir a la expresión de un tercer, segundo orden o CU, tornando ausentes el número correcto de causas.

3.5. Dedución del ERNOR y su expresión general

Primero, se presenta parte de la demostración original del RNOR de [92] para luego presentar la variación de la demostración que conduce al ERNOR. La demostración del RNOR comienza presentando el *Noisy OR* como un cociente equivalente con potencias, esto es

$$1 - P_X = \prod_{i=0}^{n-1} (1 - P_{x_i}) = \frac{[\prod_{i=0}^{n-1} (1 - P_{x_i})]^{n-1}}{[\prod_{i=0}^{n-1} (1 - P_{x_i})]^{n-2}} \tag{24}$$

Expandiendo los factores en (24) y arreglando convenientemente se llega a lo siguiente

$$\begin{aligned}
 1 - P_X = & \frac{(1 - P_{x_1}) \dots (1 - P_{x_{n-2}})(1 - P_{x_{n-1}})}{(1 - P_{x_2})(1 - P_{x_3}) \dots (1 - P_{x_{n-2}})(1 - P_{x_{n-1}})} \\
 & * \frac{(1 - P_{x_0})(1 - P_{x_2}) \dots (1 - P_{x_{n-2}})(1 - P_{x_{n-1}})}{(1 - P_{x_0})(1 - P_{x_3}) \dots (1 - P_{x_{n-2}})(1 - P_{x_{n-1}})} * \dots \\
 & * \frac{(1 - P_{x_0})(1 - P_{x_1}) \dots (1 - P_{x_{n-2}})}{(1 - P_{x_1})(1 - P_{x_2}) \dots (1 - P_{x_{n-3}})(1 - P_{x_{n-2}})}
 \end{aligned} \tag{25}$$

En (25), se observa que la influencia probabilística de x_0 falta en el primer numerador, siendo considerada la influencia de todas las causas restantes. En el segundo numerador, falta la influencia de x_1 , y así hasta que, finalmente, falta la influencia de x_{n-1} . En los denominadores, faltan las influencias por parejas, esto es, en el primer denominador, faltan x_0 y x_1 , en el segundo denominador, x_1 y x_2 y así sucesivamente. Por lo tanto, el primer numerador y denominador se pueden escribir como $1 - P_{X \setminus \{x_0\}}$ y $1 - P_{X \setminus \{x_0, x_1\}}$ respectivamente, dando por resultado la expresión (5), que es el RNOR.

Volviendo al primer paso de la demostración del RNOR, expresión (24), se intuye que se puede usar cualquier potencia mientras se mantenga la condición de que la potencia del numerador debe exceder a la del denominador en una unidad. En la demostración original [92], se eligieron $n - 1$ y $n - 2$ (n es el número de causas). Con esto, el RNOR resultante (5) siempre contendrá las probabilidades de las causas correspondientes a las combinaciones $C_{r=n-1}^n$ en el numerador, y solo n de las combinaciones $C_{r=n-2}^n$ en el denominador. Sin embargo, como se ve en (22) y (23), el ERNOR posee un mayor número de probabilidades, correspondientes a combinaciones no incluidas en el RNOR, y dicho número aumenta con respecto al número n de causas consideradas.

Al cambiar las potencias en (24) y aplicar la misma lógica que antes, es posible agrupar las probabilidades de los CU para construir las probabilidades conjuntas de combinaciones de órdenes superiores que requiere el ERNOR. No todas las potencias nos permiten obtener el ERNOR para n causas, por lo tanto, encontrar las potencias correctas que permiten alcanzar una ecuación simétrica teniendo en cuenta todas las combinaciones posibles de n causas, es el primer paso para deducir la expresión general del ERNOR.

Al aumentar las potencias a $(n, n - 1)$, $(n + 1, n)$ y así sucesivamente, la estructura RNOR siempre se logra; sin embargo, se multiplica por algunos factores de la forma $(1 - P_{x_i})$ que no son suficientes para construir las combinaciones correctas de órdenes inferiores, es decir, las combinaciones no consideradas $C_{r=n-2}^n$ en el RNOR y el resto de las combinaciones $C_{r=n-3}^n, C_{r=n-4}^n, \dots, C_{r=1}^n$. Por ejemplo, para lograr la estructura de (23) ($n = 5$) las potencias deben ser 8 y 7 ($n + 3, n + 2$), pero no funciona usar las mismas potencias para $n = 6$.

Hasta ahora, en este capítulo se ha usado el contador $i = 0, 1, \dots, n - 1$. Comenzar desde 0 era necesario por la función módulo del RNOR. De ahora en adelante, el contador $j = 1, 2, \dots, n$ se utilizará por conveniencia y la función módulo ya no es necesaria. Todas las estructuras ERNOR para cualquier número de causas n se pueden obtener aplicando la siguiente igualdad, que difiere de (24) en las potencias.

$$\begin{aligned}
 1 - P_X &= \prod_{j=1}^n (1 - P_j) \\
 &= \frac{[\prod_{j=1}^n (1 - P_{x_j})]^{q = \frac{(n-1)*C_{r=n-1}^n + (n-3)*C_{r=n-3}^n + \dots + (n-5) + C_{r=n-5}^n \dots}}{[\prod_{j=1}^n (1 - P_{x_j})]^{q-1}} \quad (r > 0)
 \end{aligned} \tag{26}$$

La potencia del numerador en (26) es q : la división entre la suma de todas las combinaciones posibles, tomando las causas $r = n - 1$ a la vez y disminuyendo a $r = n - 3$ hasta las CU ($r = 1$), entre el número de causas n . La potencia del denominador es el mismo número q , menos una unidad, para garantizar la igualdad.

La demostración de ERNOR de tercer orden coincide con el RNOR porque las potencias son $q = 6 / 3 = 2$ y $q - 1 = 1$. Estas son las mismas dos potencias utilizadas en [92]: $n - 1 = 3 - 1 = 2$ y $n - 2 = 3 - 2 = 1$. Lo anterior es lógico ya que ambas expresiones, RNOR y ERNOR son estructuralmente iguales para $n = 3$. Para $n = 4$, las potencias son $q = (3 * 4 + 1 * 4) / 4 = 4$ y $q - 1 = 3$, que ya no coinciden con las potencias $n - 1 = 4 - 1 = 3$ y $n - 2 = 4 - 2 = 2$ de (24). Para $n = 5$, las potencias son $q = (4 * 5 + 2 * 10) / 5 =$

8 y $q - 1 = 7$. Para $n = 6$, las potencias son $q = (5 * 6 + 3 * 20 + 1 * 6)/6 = 16$ y $q - 1 = 15$, y así sucesivamente.

Con las potencias elegidas en (26), la forma de obtener una expresión general para ERNOR es la siguiente. Primero, el numerador y el denominador se expanden completamente para obtener $n * q$ factores de la forma $(1 - P_{x_j})$. Luego los factores se agrupan convenientemente de forma similar a (25). En el numerador, se comienza por conformar grupos de factores que coincidan con las $C_{r=n-1}^n$ combinaciones posibles, esto consumirá $(n - 1) * C_{r=n-1}^n$ factores. Con los factores restantes, se conforman grupos coincidentes con las combinaciones $C_{r=n-3}^n$, $C_{r=n-5}^n$ y así sucesivamente mientras $r > 0$. Después de esto, todos los factores son parte de algún grupo. Para el denominador, se aplica el mismo proceso comenzando con $C_{r=n-2}^n$, luego $C_{r=n-4}^n$, etc., y nuevamente, todos los factores serán parte de algún grupo. La ecuación (27) muestra las agrupaciones.

$$\begin{aligned}
 1 - P_X = & \left[\frac{[(1-P_{x_2}) \dots (1-P_{x_{n-1}})(1-P_{x_n})]_1 * [(1-P_{x_1})(1-P_{x_3}) \dots (1-P_{x_n})]_2 * \dots * [(1-P_{x_1})(1-P_{x_2}) \dots (1-P_{x_{n-1}})]_{C_{r=n-1}^n}}{[(1-P_{x_3})(1-P_{x_4}) \dots (1-P_{x_n})]_1 * [(1-P_{x_1})(1-P_{x_4}) \dots (1-P_{x_n})]_2 * \dots * [(1-P_{x_2})(1-P_{x_3}) \dots (1-P_{x_{n-1}})]_{C_{r=n-2}^n}} \right] * \\
 & \left[\frac{[(1-P_{x_4})(1-P_{x_5}) \dots (1-P_{x_n})]_1 * [(1-P_{x_1})(1-P_{x_5}) \dots (1-P_{x_n})]_2 * \dots * [(1-P_{x_2})(1-P_{x_3}) \dots (1-P_{x_{n-2}})]_{C_{r=n-3}^n}}{[(1-P_{x_5})(1-P_{x_6}) \dots (1-P_{x_n})]_1 * [(1-P_{x_1})(1-P_{x_6}) \dots (1-P_{x_n})]_2 * \dots * [(1-P_{x_2})(1-P_{x_3}) \dots (1-P_{x_{n-3}})]_{C_{r=n-4}^n}} \right] * \\
 & (\dots) \tag{27}
 \end{aligned}$$

Note que $(1 - P_{x_1})$ falta en el primer grupo del primer numerador en (27), luego $(1 - P_{x_2})$ falta en el segundo grupo y así sucesivamente hasta el último grupo cuando se han cubierto todas las combinaciones (recuerde que los conteos ahora comienzan en uno). Por lo tanto, el primer y segundo grupo del primer numerador se pueden escribir de la siguiente manera

$$1 - P_{X \setminus \{C_1^n\}} \text{ y } 1 - P_{X \setminus \{C_2^n\}} \tag{28}$$

respectivamente, o la exclusión de las CU, una a la vez

En el segundo numerador, donde las combinaciones son $C_{r=n-3}^n$, los factores $(1 - P_{x_1})(1 - P_{x_2})(1 - P_{x_3})$ faltan en el primer grupo. Note que, en cada grupo, del

conjunto de causas X , siempre falta una tríada diferente de combinaciones $\{C_3^n\}_j$ de factores. Entonces, en el segundo numerador, el primer y segundo grupo se pueden escribir como

$$1 - P_{X \setminus \{C_3^n\}_1} \text{ y } 1 - P_{X \setminus \{C_3^n\}_2} \quad (29)$$

Utilizando las notaciones simples (28) y (29) y sus expresiones enésimas, la expresión (27) puede reescribirse como

$$1 - P^{ERNOR}(X) = \frac{\prod_{j=1}^n (1 - P_{X \setminus \{C_1^n\}_j}) * \prod_{j=1}^{C_r^n - n - 3} (1 - P_{X \setminus \{C_3^n\}_j}) \dots}{\prod_{j=1}^{C_r^n - n - 2} (1 - P_{X \setminus \{C_2^n\}_j}) * \prod_{j=1}^{C_r^n - n - 4} (1 - P_{X \setminus \{C_4^n\}_j}) \dots} \text{ mientras } r > 0 \quad (30)$$

donde igual razonamiento se aplicó a los grupos de los denominadores. La ecuación (30) es la expresión general para la estructura del ERNOR. Mediante ella se calculan las probabilidades conjuntas de las combinaciones de causas provocando un efecto. Note que el primer producto del numerador coincide con el numerador del RNOR cuando se expande. El primer producto del denominador contiene el denominador del RNOR, pero también introduce todas las combinaciones faltantes que se descartan cuando $n > 3$. Además, el resto de los productos (no considerados en el RNOR) aseguran la simetría de la ecuación para cualquier número de causas. Para $n \leq 3$, el modelo ERNOR es igual al RNOR.

ERNOR es estático si las probabilidades de cualquier orden, consultadas al experto, se introducen como constantes, entonces las probabilidades calculadas son valores puntuales también. Siendo estático, las probabilidades consultadas y calculadas se pueden utilizar para completar una TPC, útil en modelos gráficos como las RB. Por otro lado, las influencias de las causas pueden considerarse dependientes del tiempo usando las TR (9) y (10) y el ERNOR es dinámico. Como el ERNOR dinámico es una ecuación continua y explícita, la curva resultante se puede usar en modelos que no se basan en valores discretos, como una nueva compuerta lógica en AF.

Desafortunadamente, no fue posible encontrar transformaciones que permitieran introducir valores de expertos más allá del segundo orden sin afectar el comportamiento

correcto de la FDA resultante. Por esta razón, la versión dinámica del ERNOR tiene como entradas las estimaciones de las influencias de las CU y las combinaciones de 2do orden. Además, se debe definir cada FDP o FDA para cada causa. Con los datos anteriores, el ERNOR se puede construir para cualquier número de causas de manera recursiva (es decir, es necesario calcular expresiones de 3er orden, luego 4to y así sucesivamente). Si bien el no poder introducir combinaciones dinámicas más allá del 2do orden es una restricción del modelo dinámico, el autor considera que en la práctica no es un problema mayor ya que los expertos pueden tener buenas aproximaciones sobre las probabilidades de las CU y las probabilidades conjuntas de dos causas, sin embargo, cuantas más causas estén involucradas en las probabilidades conjuntas consultadas, mayor es el esfuerzo requerido del experto para proporcionar un valor confiable, o de facto, puede no saber la respuesta. En los casos donde hay muchas causas, el cálculo de probabilidades conjuntas mediante (30) es una mejor opción que encuestarlas directamente.

3.6. Análisis del ERNOR

El modelo ERNOR, como una generalización del RNOR, tiene la misma desventaja con respecto a la causalidad positiva. Esto implica que $P_x^E > P_X^E$ con $x \in X$ podría generar valores probabilísticos ilógicos para combinaciones de orden superior a X , donde el conjunto X está presente. La violación de la causalidad positiva también se produce si las probabilidades conjuntas introducidas son de interferencia. Debido a lo anterior, se recomienda el uso del modelo ERNOR con probabilidades sinérgicas o al menos ICI. Por otro lado, las probabilidades que pueden hacer que cualquiera de los factores en el denominador de (24) sea cero, indefinen la ecuación. Este aspecto se arrastra del RNOR, por lo que las probabilidades encuestadas para ser introducidas al modelo no pueden ser iguales a 1. Si se desean introducir probabilidades iguales a 1, ha de usarse una compuerta OR determinista.

Como se demostrará con un ejemplo numérico en la sección 3.7, las sinergias para cuatro causas o más del ERNOR son más conservadoras que en el modelo RNOR. En esta sección se explica la razón de este comportamiento y su justificación. Siguiendo los

análisis realizados en [92], pero ahora aplicados al ERNOR, la relación de éste con el modelo N-OR puede expresarse de la siguiente manera

$$1 - P_X^{ERNOR} = S_X * (1 - P_X^{N-OR}) \quad (31)$$

donde S_X es un factor que, en el caso de ser igual a 1, significa que ambos modelos son iguales. Para $S_X < 1$, los valores del ERNOR son mayores que el N-OR y se considera la sinergia, lo contrario implica interferencia o inhibición. A continuación, se asumen interacciones sinérgicas. Al aplicar la expresión (31) a una expresión de 3er orden (por ejemplo la expresión (11) pero usando las causas x_1, x_2, x_3 y recordando que RNOR es igual al ERNOR hasta 3er orden) y observando que $S = 1$ para las CU, se obtiene

$$S_{x_1, x_2, x_3} * (1 - P_{x_1, x_2, x_3}^{N-OR}) = \frac{[S_{x_1, x_2} * (1 - P_{x_1}) * (1 - P_{x_2})] * [S_{x_1, x_3} * (1 - P_{x_1}) * (1 - P_{x_3})] * [S_{x_2, x_3} * (1 - P_{x_2}) * (1 - P_{x_3})]}{[1 * (1 - P_{x_1})] * [1 * (1 - P_{x_2})] * [1 * (1 - P_{x_3})]} \quad (32)$$

Cancelando términos, la sinergia para tres causas es

$$S_{x_1, x_2, x_3} = S_{x_1, x_2} * S_{x_1, x_3} * S_{x_2, x_3} \quad (33)$$

y si otra causa x_4 es añadida, las otras sinergias para el 3er orden son

$$\begin{aligned} S_{x_1, x_2, x_4} &= S_{x_1, x_2} * S_{x_1, x_4} * S_{x_2, x_4} \\ S_{x_2, x_3, x_4} &= S_{x_2, x_3} * S_{x_2, x_4} * S_{x_3, x_4} \\ S_{x_1, x_3, x_4} &= S_{x_1, x_3} * S_{x_1, x_4} * S_{x_3, x_4} \end{aligned} \quad (34)$$

Siguiendo un proceso similar a como se obtuvo (32) y cancelando términos, la sinergia del ERNOR de 4to orden (por ejemplo, usando (22) pero con causas x_1, x_2, x_3, x_4) posee la siguiente estructura

$$S_{x_1, x_2, x_3, x_4} = \frac{S_{x_1, x_2, x_3} * S_{x_1, x_2, x_4} * S_{x_2, x_3, x_4} * S_{x_1, x_3, x_4}}{S_{x_1, x_2} * S_{x_1, x_3} * S_{x_2, x_3} * S_{x_1, x_4} * S_{x_2, x_4} * S_{x_3, x_4}} \quad (35)$$

La ecuación (35) es la forma general en la que se consideran las sinergias con cuatro causas. Sustituyendo la expresión (33) y el conjunto de expresiones (34), en (35), se obtiene

$$S_{x_1, x_2, x_3, x_4} = \frac{(S_{x_1, x_2} * S_{x_1, x_3} * S_{x_2, x_3}) * (S_{x_1, x_2} * S_{x_1, x_4} * S_{x_2, x_4}) * (S_{x_2, x_3} * S_{x_2, x_4} * S_{x_3, x_4}) * (S_{x_1, x_3} * S_{x_1, x_4} * S_{x_3, x_4})}{S_{x_1, x_2} * S_{x_1, x_3} * S_{x_2, x_3} * S_{x_1, x_4} * S_{x_2, x_4} * S_{x_3, x_4}} \quad (36)$$

Simplificando factores queda

$$S_{x_1, x_2, x_3, x_4} = S_{x_1, x_2} * S_{x_1, x_3} * S_{x_2, x_3} * S_{x_1, x_4} * S_{x_2, x_4} * S_{x_3, x_4} \quad (37)$$

La ecuación (36) implica que las sinergias de 2do orden están consideradas dos veces en la expresión de las sinergias de 4to orden, es decir, en el numerador. De esta forma, es posible afirmar que el ERNOR funciona como una ley de inclusión exclusión de sinergias, ya que las sinergias repetidas en el numerador de (36) se cancelan con las del denominador, dando lugar a la expresión (37). Siendo así, se alcanza un balance en el cual el efecto de las combinaciones de las causas se considera una sola vez.

Sin embargo, aplicando el mismo razonamiento al RNOR de 4to orden, por ejemplo, a la ecuación (15) pero usando las cuatro causas x_1, x_2, x_3, x_4 , el resultado es

$$S_{x_1, x_2, x_3, x_4} = S_{x_1, x_2} * (S_{x_1, x_3})^2 * S_{x_2, x_3} * S_{x_1, x_4} * (S_{x_2, x_4})^2 * S_{x_3, x_4} \quad (38)$$

La expresión (38) demuestra que debido a la asimetría del RNOR, existen dos sinergias que siempre se van a considerar dos veces, sobreestimando las probabilidades conjuntas de las causas en la provocación de un efecto. Las dos sinergias que se contabilizan doble dependerán del orden en que se tomen las variables, de ahí la asimetría del RNOR.

Las conclusiones anteriores son aplicables a las ecuaciones de cinco causas y más, donde se puede demostrar que, al realizar un análisis similar, algunas sinergias se consideran más de dos veces si se viola la estructura del ERNOR (30). Este análisis no se presenta aquí debido a que involucra grandes expresiones.

Finalmente, una breve discusión es proporcionada acerca de cómo considerar causas que se inhiben. En algunos problemas es deseable tener en cuenta las causas que, cuando están presentes, reducen la probabilidad de lograr un efecto. Las causas inhibitorias, cuando están presentes simultáneamente con causas que se refuerzan,

pueden ser manejadas por el ERNOR de la misma manera en que Gossink *et al.* [96] lo han propuesto para el RNOR. Básicamente, las causas se pueden agrupar en dos conjuntos: un conjunto X^+ para las causas que aumentan la probabilidad de lograr el efecto, y un conjunto X^- para aquellas que inhiben la probabilidad. La forma de la ecuación propuesta por Gossink *et al.*, pero usando el ERNOR es

$$P_{X^+,X^-}^{ERNOR} = (1 - P_{X^-}^{ERNOR}) * P_{X^+}^{ERNOR} \quad (39)$$

En la expresión (39), cuando las causas inhibitorias están ausentes, la probabilidad conjunta resulta sólo del aporte de las causas que se refuerzan. Cuando las causas que se refuerzan están ausentes, la probabilidad conjunta es nula, lo que significa que no hay ningún efecto positivo que inhibir. Cuando ambos tipos de causas están presentes, existe un equilibrio que depende de cuántas causas existen en cada conjunto y de los valores de las probabilidades independientes y conjuntas que provocan o inhiben el efecto.

3.7. Ejemplo cuantitativo

Para demostrar el comportamiento del ERNOR, se realizan análisis comparativos con el modelo RNOR y el modelo N-OR, primero calculando valores estáticos y luego mostrando el comportamiento dinámico.

La Tabla 4 presenta una comparación de los modelos puntuales, N-OR, RNOR y ERNOR considerando 5 causas. Los valores de las CU y de segundo orden son ejemplos de lo que podrían ser valores proporcionados por un experto (columnas nombradas Exp.) y son los datos de entrada, los demás (probabilidades de 3er, 4to y 5to ordenes), son resultado de los respectivos modelos. Estos datos son sinérgicos ya que los valores proporcionados por los expertos para el segundo orden son más altos que los valores calculados por el N-OR. Con esto, se asegura que las probabilidades de las combinaciones de orden superior también sean sinérgicas. Los resultados reflejan ese hecho tanto para el RNOR, como se esperaba, como para el nuevo modelo ERNOR. Recapitulando, los resultados de la probabilidad conjunta de tercer orden son los mismos para el RNOR y el ERNOR porque ambas expresiones son simétricas para tres causas. Las diferencias están en el 4to y 5to orden, donde los valores ya no son coincidentes. De hecho, el ERNOR proporciona valores más pequeños que el RNOR y la razón se deriva

de la sobreestimación de las sinergias del RNOR, como se explica en la sección 3.6 (compare las expresiones (37) para el ERNOR con la (38) para el RNOR de 4to orden).

Tabla 4: Comparación entre los modelos estáticos N-OR, RNOR y ERNOR.

Causas unitarias (CU)	Exp.		3er orden	N-OR	RNOR/ERNOR	
x_1	0.05		x_1, x_2, x_3	0.2733	0.3243	
x_2	0.10		x_2, x_3, x_4	0.3880	0.4498	
x_3	0.15		x_1, x_3, x_4	0.3540	0.4277	
x_4	0.20		x_1, x_2, x_4	0.3160	0.3811	
x_5	0.25		x_1, x_2, x_5	0.3588	0.3944	
2do orden	N-OR	Exp.	x_2, x_3, x_5	0.4263	0.4729	
x_1, x_2	0.1450	0.1600	x_1, x_3, x_5	0.3944	0.4510	
x_1, x_3	0.1925	0.2100	x_3, x_4, x_5	0.4900	0.5569	
x_2, x_3	0.2350	0.2600	x_2, x_4, x_5	0.4600	0.5049	
x_1, x_4	0.2400	0.2800	x_1, x_4, x_5	0.4300	0.5032	
x_2, x_4	0.2800	0.3000	4to orden	N-OR	RNOR	ERNOR
x_3, x_4	0.3200	0.3500	x_1, x_2, x_3, x_4	0.4186	0.5473	0.5241
x_1, x_5	0.2875	0.3100	x_1, x_2, x_3, x_5	0.4549	0.5474	0.5339
x_2, x_5	0.3250	0.3300	x_1, x_2, x_4, x_5	0.4870	0.6014	0.5761
x_3, x_5	0.3625	0.3900	x_1, x_3, x_4, x_5	0.5155	0.6575	0.6221
x_4, x_5	0.4000	0.4300	x_2, x_3, x_4, x_5	0.5410	0.6537	0.6277
			5to orden	N-OR	RNOR	ERNOR
			x_1, x_2, x_3, x_4, x_5	0.5640	0.8045	0.6881

Los valores de la Tabla 4 pueden ser utilizados para completar una TPC y representan las probabilidades conjuntas (excepto por las CU) de las causas conllevando a un efecto cuando están presentes. La probabilidad de no lograr el efecto es el complemento de cada valor mostrado.

En la Figura 3 se muestra una comparación del N-OR dinámico (DN-OR), el DRNOR y el ERNOR dinámico. Para este ejemplo, se utilizaron las mismas probabilidades de entrada que para calcular la Tabla 4. Las distribuciones acumuladas asignadas a las causas son del tipo Weibull con los parámetros que se muestran en la Tabla 5.

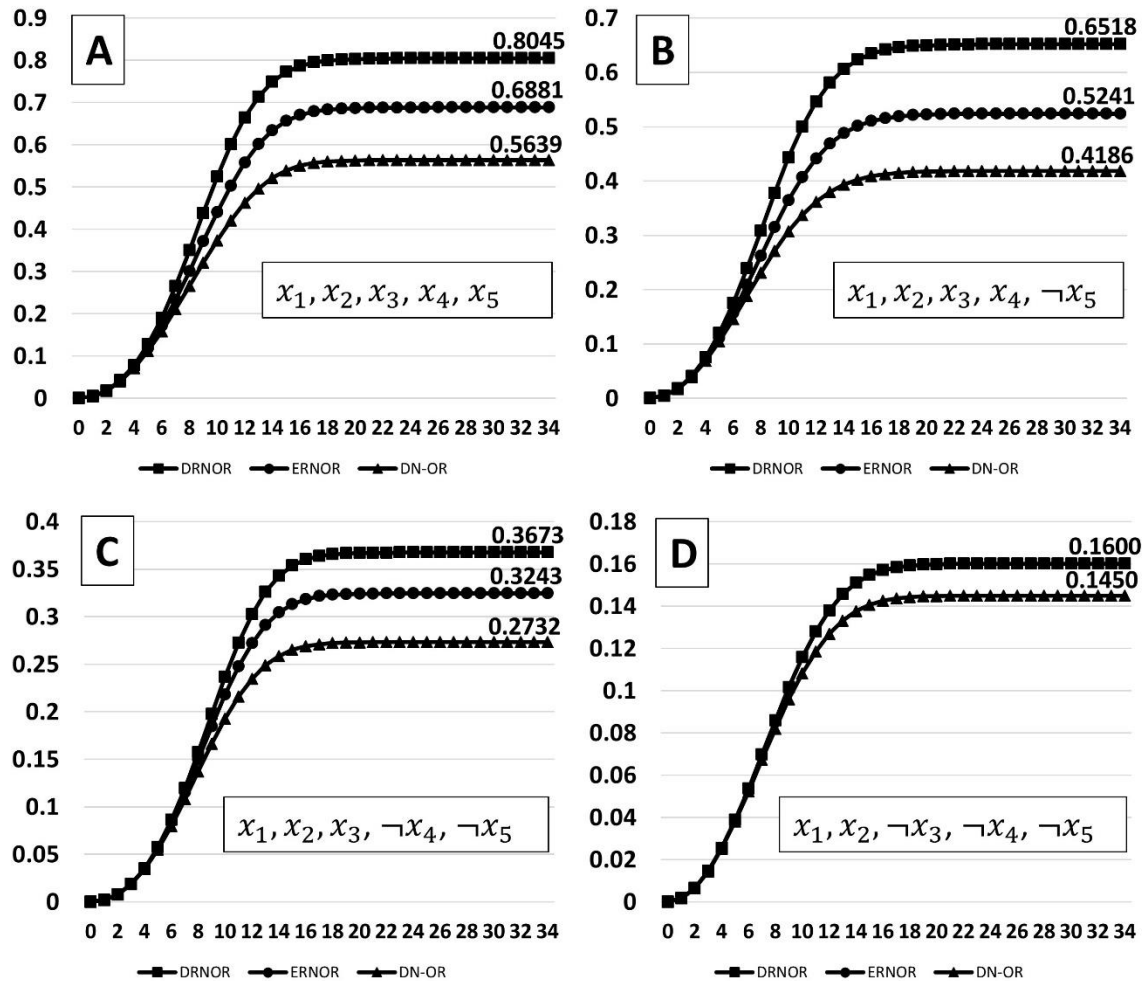


Figura 3: Comportamiento dinámico de las probabilidades conjuntas según los modelos DN-OR, DRNOR y ERNOR.

Tabla 5: Parámetros de la distribución Weibull de las causas.

	F_{x_1}	F_{x_2}	F_{x_3}	F_{x_4}	F_{x_5}
$W(\text{forma}; \text{escala})$	$W(3; 10)$	$W(2; 8)$	$W(3; 10)$	$W(2; 9)$	$W(4; 12)$

En la Figura 3, el número de pasos temporales es 34 para garantizar que cada distribución acumulada se acerque a 1, donde cada causa puede considerarse como presente. En la Figura 3A, todas las causas van de ausente a presente de acuerdo con sus distribuciones acumuladas y el número sobre cada curva corresponde al paso temporal 34 para cada modelo. Como se esperaba, el valor final etiquetado coincide con el valor respectivo que se muestra en la Tabla 4, excepto por un pequeño error producto del redondeo dado que ninguna distribución acumulada es uno, excepto en infinito. Se

observa que, dadas las sinergias consideradas, $DRNOR > ERNOR > DN-OR$ para todo el dominio de tiempo.

La Figura 3B se obtiene ajustando el tiempo de x_5 a cero, por lo tanto, está ausente. Se observa que tanto el DN-OR como el ERNOR aceptan la reducción, coincidiendo con los valores respectivos de la Tabla 4 para x_1, x_2, x_3, x_4 , equivalente a $x_1, x_2, x_3, x_4, \neg x_5$. Sin embargo, el valor final DRNOR de 0.6518 no coincide con el valor 0.5473 de la combinación x_1, x_2, x_3, x_4 en la Tabla 4 y este es precisamente el efecto negativo de la asimetría y la razón por la cual se desarrolló el modelo ERNOR. Un comportamiento similar se muestra en la Figura 3C donde x_4, x_5 están ausentes del conjunto original de causas y nuevamente, los valores finales DN-OR y ERNOR coinciden con sus valores respectivos en la Tabla 4 para x_1, x_2, x_3 mientras que el RNOR no coincide y su valor es más grande. Recuerde que en la sección 3.3 se demostró que el DRNOR no acepta reducciones de 4to a 3er orden.

Finalmente, en la Figura 3D, donde solo las causas x_1, x_2 están presentes del conjunto original, ERNOR y RNOR coinciden entre sí y con la Tabla 4 porque los problemas de asimetría ya no están presentes. No se muestra el caso donde solo hay una causa presente, y los tres modelos son coincidentes. Los análisis se realizaron haciendo primero ausente la causa x_5 , luego x_5, x_4 y así sucesivamente, pero cualquier causa podría tornarse ausente en un orden arbitrario y las conclusiones siguen siendo válidas.

El análisis demuestra que el modelo ERNOR se comporta de manera lógica porque las expresiones obtenidas para cualquier número de causas pueden reducirse cuando un subconjunto de causas está presente o parcialmente presente y otras causas no lo están. La importancia de este aspecto se debe al hecho de que, si el ERNOR se va a introducir como una compuerta lógica en un programa computacional dinámico, es razonable suponer que el usuario definirá un número máximo de causas n (o señales de entrada a la compuerta) para un problema dado desde el principio. Así, el modelo ERNOR se establece inicialmente para un orden n de causas. Luego, durante la simulación, algunas causas (o señales) se pueden tornar ausentes en el tiempo t , o disminuyen su probabilidad de estar presentes. Si dichas causas se contemplan como si fueran factores que influyen en el aumento de la probabilidad de fallo de un componente, estos factores

pueden estar presentes, tornarse ausentes o tomar valores intermedios en cualquier momento debido a cambios en las condiciones de operación, o acciones de mantenimiento que eliminen o mitiguen determinados factores. En el capítulo V se desarrolla este concepto para determinar de forma dinámica, la influencia de que tienen ciertos MD sobre otros, y sobre la probabilidad de fallo de un componente, utilizando el ERNOR.

3.8. Resumen y conclusiones parciales: Recursive Noisy OR Extendido

En el presente capítulo se ha analizado el modelo RNOR, con el objetivo de calcular probabilidades puntuales conjuntas resultantes de combinaciones de causas binarias, como parte del proceso de cuantificación de las TPC de una RB. También se analizó con el objetivo de extenderlo a una versión dinámica que genera distribuciones acumuladas de las probabilidades conjuntas de las causas, basadas en el nivel de presencia de estas últimas. Ambos con la motivación de cuantificar las interacciones (en términos de probabilidad puntual y dependientes del tiempo) de los MD en un componente para ser aplicados a turbinas de vapor. En el proceso se identificaron limitaciones como la asimetría del RNOR, que imposibilitaron dichos objetivos haciendo uso de este, por lo que fue desarrollado y demostrado un nuevo modelo, el ERNOR. Este modelo resuelve el problema de la asimetría y sus consecuencias cuando las causas se tornan ausentes. De los análisis presentados, se concluye que:

1. El problema de la asimetría del modelo RNOR cuando se construye para más de 3 causas, no es equivalente a sus versiones construidas para una cantidad menor de causas, por lo que imposibilita su uso en aplicaciones donde las causas se tornen presentes o ausentes ante la necesidad del usuario.
2. El problema de la asimetría es producto de que en el RNOR se considera más de una vez la sinergia de pares de causas, siendo más fuerte entre más causas sean consideradas en el modelo.
3. Se han propuesto las transformaciones para considerar las causas como dependientes del tiempo a partir de valores constantes que pueden encuestarse a expertos. Dichas transformaciones aplican a las causas unitarias y conjuntas

dos a dos, no siendo posible determinar estructuras para órdenes superiores, por lo que este es trabajo futuro.

4. Se desarrolló y demostró un nuevo modelo, el ERNOR, que puede manejar probabilidades puntuales y continuas, siendo una versión extendida del RNOR que resuelve el problema de la asimetría.
5. El ERNOR muestra un comportamiento coherente cuando algunas causas están ausentes y otras no, coincide con el RNOR hasta 3er orden y mantiene las mismas restricciones relacionadas con la preservación de la causalidad positiva.
6. El modelo ERNOR puede manejar probabilidades puntuales encuestadas a expertos para calcular valores puntuales probabilísticos sinérgicos de las influencias de cualquier número de causas y llenar las TPC de las RB. Este modelo será utilizado en el Capítulo IV para cuantificar las interacciones entre los MD en los álabes de turbina de vapor.
7. La versión dinámica del ERNOR produce funciones de distribución acumuladas sinérgicas de las probabilidades conjuntas de las causas, que dependen del nivel de presencia de cada una. Este enfoque puede usarse en árboles de fallos como una compuerta lógica especial para modelar situaciones donde existen factores que aumenten la probabilidad de fallo de un componente. En esta investigación su utilidad será expuesta en el Capítulo V como método para considerar las dependencias dinámicas de los MD.

Capítulo IV: Evaluación de los mecanismos de daño de los álabes de la turbina de vapor usando una red bayesiana

En el Capítulo II se había planteado la sub-hipótesis de que las redes bayesianas ofrecen una solución adecuada para modelar las dependencias condicionales que existen entre los MD, y de estos con la ubicación de los álabes en las turbinas de vapor, proporcionando una herramienta que permitiría la identificación de los MD que contribuyen a los fallos. Esta sub-hipótesis fue parcialmente comprobada en ese mismo capítulo a través del estudio de los fundamentos matemáticos de las RB y la revisión de la bibliografía pertinente. Para cuantificar la RB se concluyó que el RNOR poseía mejores capacidades que los demás métodos de cuantificación. La factibilidad del RNOR para los modelos estáticos y dinámicos a desarrollar, objetivos de la presente tesis, fue comprobada en el Capítulo III, donde se determinó que no era factible tal y como se plantea, por lo que fue necesario desarrollar el nuevo modelo ERNOR para corregir los problemas de asimetría y extenderlo a variables dependientes del tiempo.

Dados los análisis previos, y para probar la sub-hipótesis, en este capítulo se desarrolla un modelo basado en RB que tiene en cuenta los MD que afectan la confiabilidad de los álabes. El modelo es una herramienta analítica que se puede complementar a las otras técnicas de mantenimiento e inspección disponibles para ayudar en la identificación y ubicación de los MD que contribuyen a los fallos. Con este fin, el modelo desarrollado considera la dependencia probabilística condicional entre MD, modos de fallo y sus ubicaciones en los álabes rotatorios. Para cuantificar la RB, se ha desarrollado un nuevo método de cálculo de sus TPC basado en el juicio de expertos. El método de cuantificación combina el ERNOR desarrollado en el capítulo anterior con un método de clasificación de la susceptibilidad de las ubicaciones (fila y parte del álabe) a los MD.

Para demostrar el desarrollo y la utilidad del modelo, la BN se construyó considerando los MD más representativos que afectan a los álabes en una turbina nuclear de baja presión. El modelo presenta un nivel más refinado de granularidad que proporciona

información más detallada, útil para la toma de decisiones en las actividades de mantenimiento.

4.1. Metodología general

El desarrollo del modelo se lleva a cabo mediante una serie de pasos lógicos que abarcan desde la concepción del esqueleto de la RB, su cuantificación, validación y los tipos de análisis que pueden realizarse. La Figura 4 muestra el diagrama de flujo de la metodología seguida para obtener la RB.

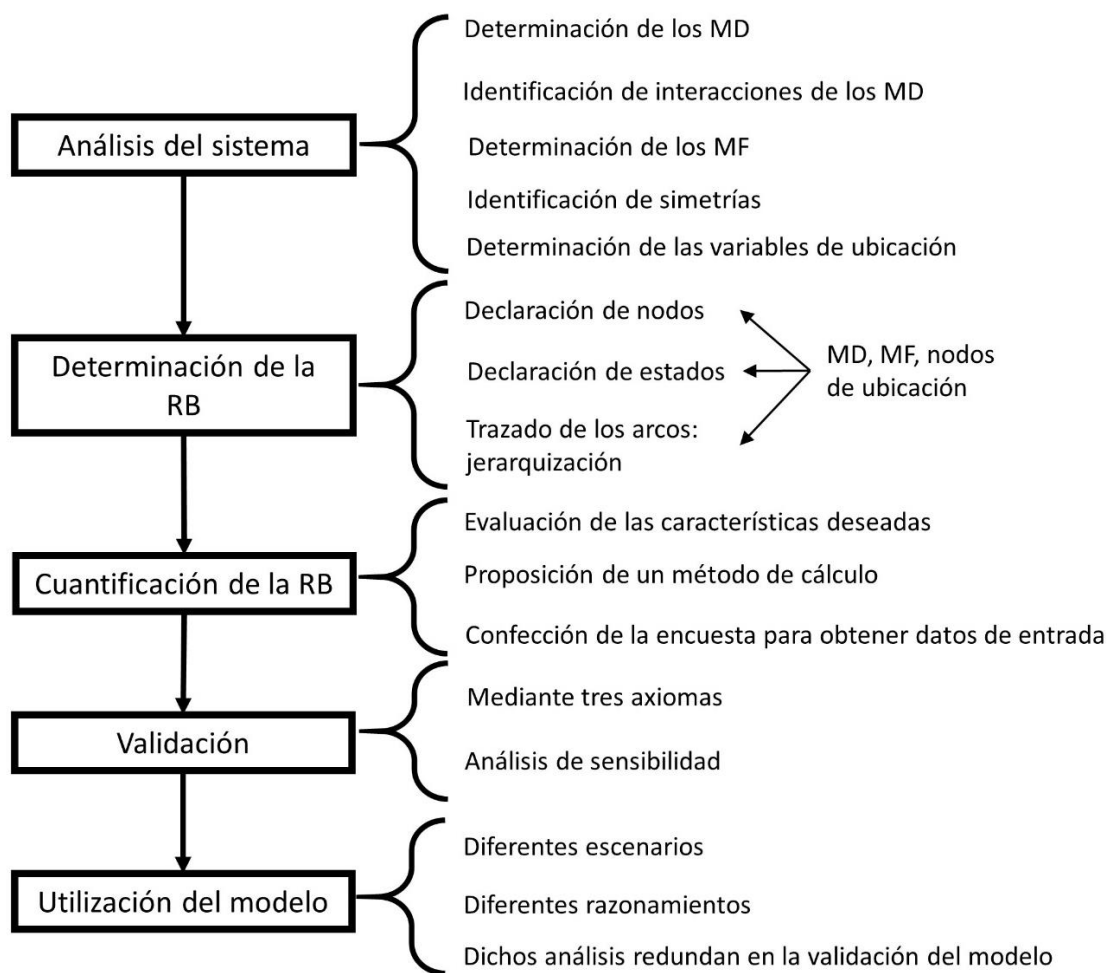


Figura 4: Metodología para desarrollar el modelo de RB.

4.2. Análisis de sistema

El análisis de sistema tiene como objetivos principales la familiarización con el sistema objeto de estudio y las variables de interés de acuerdo con el propósito del modelo que

se quiere desarrollar. Varios de estos aspectos ya han sido cubiertos en esta investigación a lo largo de la Introducción y el Capítulo I. Recapitulando, los MD que se tomarán en cuenta en este modelo son los descritos en la sección 1.2: impacto por goteo, picaduras, fatiga mecánica simple y asistida por corrosión, SCC y daño por fricción.

4.2.1. Interacción entre los mecanismos de daño

A continuación, se presenta un resumen de las dependencias cualitativas entre los MD, los MF a los que tributan y las simetrías que pueden ser explotadas en una turbina de vapor.

Por ejemplo, la exposición prolongada al impacto de las gotas, típicamente varios años, conduce a un aumento de la rugosidad de la superficie [27, p. 2], que provoca concentradores de tensión. La pérdida de material que se produce puede cambiar la frecuencia natural de los álabes, provocando resonancia [5, Sec. 4.1]. Estos efectos aumentan la probabilidad de fatiga, que propaga el daño en forma de grieta. El SCC y la CF pueden comenzar por sí mismos, por lo que no es necesario una picadura, pero la presencia de picaduras aumenta la probabilidad de iniciación de los primeros [22], [97] debido a que sirven como concentradores de tensión y producen un ambiente de corrosión agresivo dentro de sus cráteres. La fricción reduce significativamente la resistencia a la fatiga de las aleaciones. La fricción también se ha asociado al inicio de SCC y CF [22], [31], [98], actuando como un concentrador de estrés en ambientes corrosivos. El cambio en el mecanismo que propaga el agrietamiento es también posible. En un componente cargado mecánicamente de forma estática o cuasi estática, si las cargas cíclicas aumentan, la propagación de la grieta puede pasar de SCC a CF [22], [29]. Esta transición también se conoce como carga ondulada (el término en inglés es *ripple load*), o la superposición de la carga cíclica sobre la estática [99].

4.2.2. Modos de fallo

Para el propósito de este modelo, se usa la definición de fallo de álabe, traducida del inglés del informe de EPRI [1, p. 1_1]: “La situación en la que una inspección de la turbina revela que uno o más álabes han perdido la capacidad de realizar su función de una forma segura y confiable, y que es necesario un trabajo correctivo para poner la unidad en línea.”

Del análisis del enunciado anterior surgen dos puntos de vista para considerar los modos de fallo. El primero es considerando la disponibilidad de la turbina, que es el enfoque clásico de super componente, en el cual la misma está funcionando o no. El segundo es el enfoque del fallo de los álabes sometidos a los MD. Ambos enfoques son válidos y se diferencian en la capacidad que se tiene de observar, medir o predecir la forma en la que falla el sistema. Ambos se explican a continuación.

El primer enfoque responde a la forma clásica de ver la disponibilidad de la turbina: funciona o no funciona desde una visión macro. Teniendo en cuenta la definición del fallo del álabe se tienen dos modos de fallo de la turbina como super componente:

Fallo de turbina en inspección (fallo en parada programada). Se detecta en paro planificado y es necesario corregir. Al menos un álabe resulta incapaz realizar su función de una forma segura y confiable, aunque pudieran identificarse varios elementos ya fallados. En este caso cualquiera de los MD pudo ser la causa del fallo (erosión, corrosión o agrietamiento), sin un paro súbito.

Fallo de turbina en operación (fallo forzado). La turbina es detenida de forma automática o deliberada ante la alteración de los parámetros monitoreados o la sospecha de fallo.

El segundo enfoque responde al modo de fallo del álabe como elemento de interés, afectado por los MD mencionados en el Capítulo I.

Fallo por Corrosión. Implica las picaduras que se desarrollan por la acción de agentes químicos presentes en el vapor, que con el tiempo se hacen más abundantes y profundas. En dependencia de la magnitud del daño y el juicio ingenieril, puede ser necesario aplicar correcciones a las superficies afectadas o reemplazar el elemento

Fallo por Erosión. Implica daño por impacto repetido de gotas a gran velocidad. Se puede llegar a perder eficiencia en la fila y por último puede ocurrir que la pérdida de material erosionado cambie la frecuencia natural del elemento. Su reparación está sujeta también a juicio ingenieril en dependencia de la magnitud del daño.

Fallo por agrietamiento. Ocurre cuando alguno de los mecanismos que conllevan a los dos modos anteriores se combinan con otros mecanismos propagadores del daño,

llegando la detección de una grieta peligrosa, con un respectivo trabajo de corrección, o a la fractura del elemento.

4.2.3. Simetrías del sistema

Este paso tiene como objetivo la identificación de todas las posibles simetrías que puedan ser útiles con el fin de simplificar el modelo, lo cual evidentemente simplificará también su cuantificación y el esfuerzo necesario para entenderlo por terceras personas.

Las simetrías en este caso se ven desde el punto de vista de los MD y la mejor forma de explicar el enfoque es ejemplificando con el propio sistema objeto de estudio. El tema de la simetría ya se ha tratado en el Capítulo I, específicamente en sus conclusiones. Una turbina varía sus parámetros de vapor a lo largo del eje axial, a medida que este va perdiendo energía, y a la misma vez el diseño de cada fila va cambiando, lo cual condiciona la susceptibilidad de cada fila a ciertos mecanismos y a otros no. Por esta razón, el modelo puede simplificarse aplicando una variable de ubicación que coincida con la fila del álabe. Esta variable condiciona los MD y las interacciones a lo largo de la turbina y cada fila puede considerarse como una población de elementos similares.

Por otra parte, la turbina posee simetría radial en cada fila de álabes. Para cada una, las condiciones de operación del vapor y de estrés mecánico varían de acuerdo con la parte del álabe que se esté analizando. Por ejemplo, las raíces de los álabes son propensas a sufrir de daño por rozamiento contra la estructura que los fija a los discos del rotor, generándose agrietamiento. Las bandas de cobertura de los álabes, por otro lado, están sujetas a una mayor erosión, porque la velocidad lineal aumenta con la distancia al rotor. Entonces, es posible descomponer el álabe en sus partes o porciones de acuerdo con el nivel de granularidad deseado, por lo que puede declararse una segunda variable de ubicación que contemple dichas partes, las cuales están condicionadas por la variable fila. Ambas variables de ubicación poseen múltiples estados.

La Figura 5A es una representación axialmente simétrica simplificada de una sección de baja presión de una turbina de vapor. Se señalan los tamaños relativos y el etiquetado de las filas de álabes, que es la primera variable de ubicación anteriormente explicada. También se representa la dirección del flujo de vapor y el lugar donde normalmente

comienza la ZTF en diseños nucleares [22, p. 121]. La Figura 5B muestra la segunda variable de ubicación, que es la separación de los álabes en partes/porciones. En esta investigación se consideran las siguientes cuatro partes/porciones del álabe:

- 1- Hoja o superficie de trabajo (*airfoil*), que incluye la cobertura de erosión.
- 2- Zona de la raíz: Raíz y plataforma.
- 3- Alambre de amarre o lengüeta, según el caso y si existe.
- 4- Zona de cobertura: Espigas (*tenons*) con banda de recubrimiento o envoltura (*cover band or shroud*) y remache (*rivet*).

Tenga en cuenta que algunos diseños pueden carecer de alambres de sujeción o cubiertas. La discretización elegida permite el entendimiento de la metodología sin pérdida de generalidad.

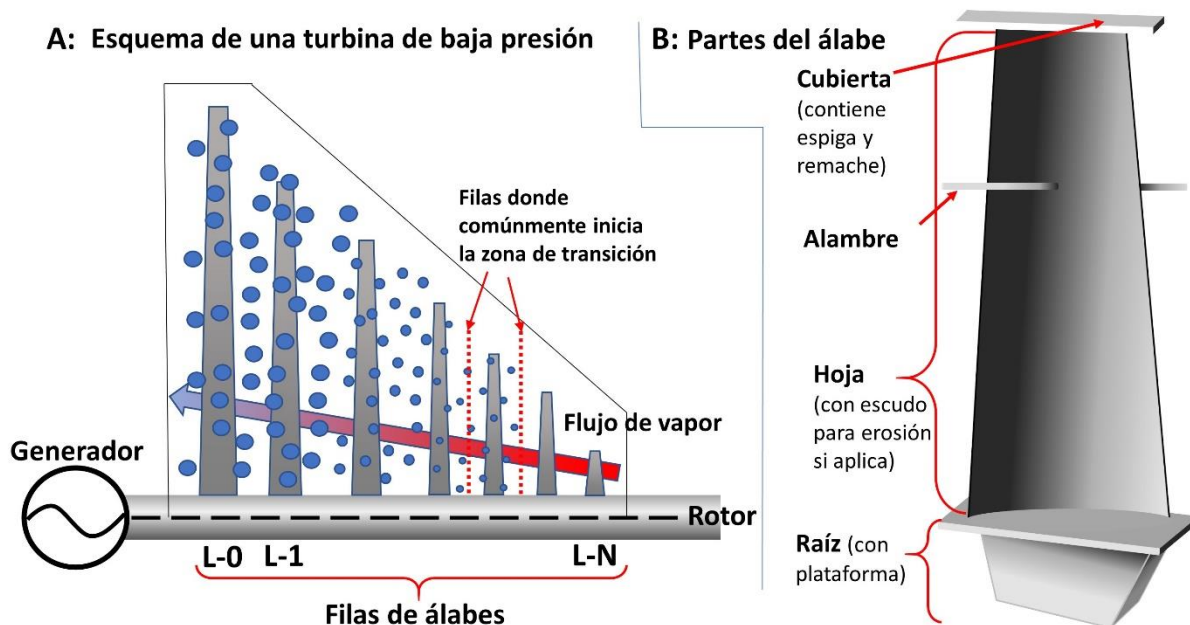


Figura 5: (A) Esquema simplificado de una sección de baja presión mostrando las filas de álabes. (B) Discretización utilizada en este estudio de un álabe (derecha).

4.3. Determinación de la RB

La Figura 6 muestra el modelo de RB para álabes de turbinas de centrales nucleares. En este capítulo, se usa la versión académica de GeNie Modeler [100] como programa computacional para el manejo de RB. La estructura de la red (nodos, estados y arcos) se determinó mediante la investigación bibliográfica, específicamente utilizando la

información resumida en los puntos de la sección 4.2. Los nodos con “MD” al final de su nombre son mecanismos de daño; los que tienen una “MF” al final son modos de fallo producidos por los MD.

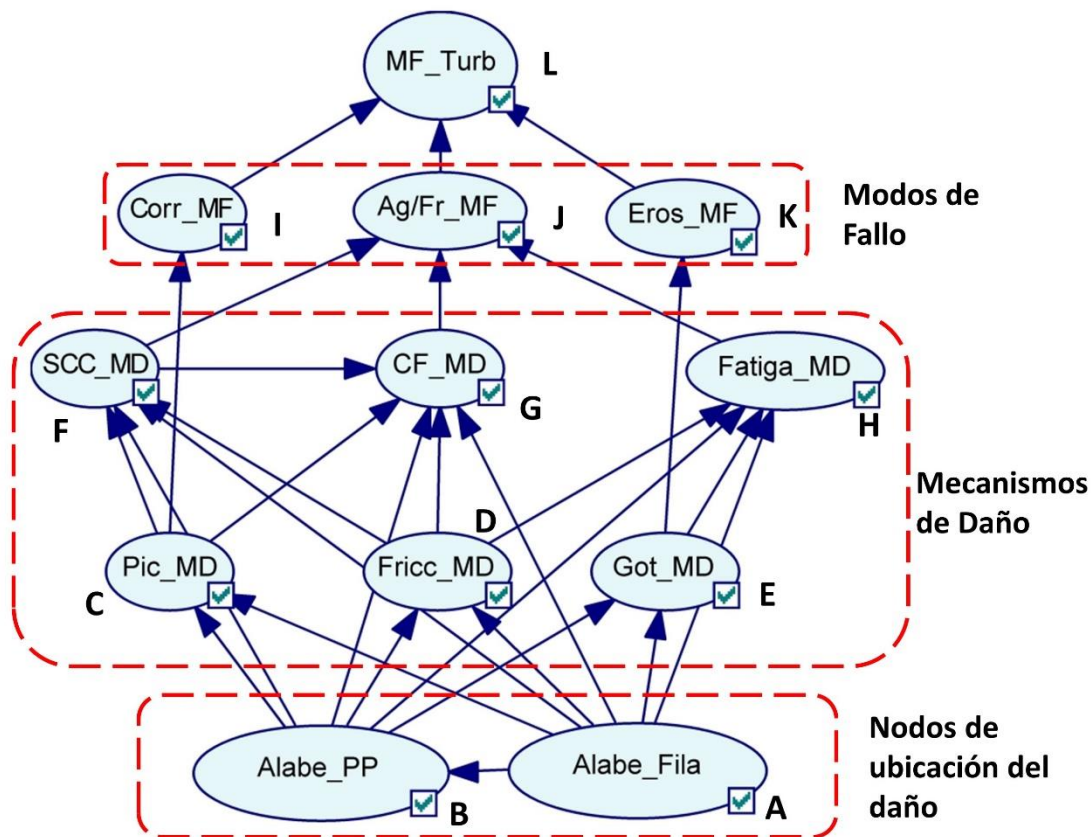


Figura 6: Red bayesiana que describe los modos de fallo y mecanismos de daño en una turbina de vapor nuclear de baja presión.

Las dependencias condicionales de los nodos están representadas por la probabilidad conjunta (40). Las letras mayúsculas se han utilizado en lugar de los nombres de los nodos para simplificar.

$$\begin{aligned}
 P(\text{conjunta}) = & P(L|K,J,I) * P(I|C) * P(J|H,G,F) * P(K|E) * P(F|D,C,B,A) \\
 & * P(G|F,D,C,B,A) * P(H|E,D,B,A) * P(C|B,A) * P(D|B,A) \\
 & * P(E|B,A) * P(B|A) * P(A)
 \end{aligned}
 \tag{40}$$

Una descripción de todos los nodos es provista en la Tabla 6.

Tabla 6: Descripción de los nodos en la RB.

Nombre del nodo (estados posibles)	Descripción
Ubicación del daño	
Alabe_Fila (L-0, L-1, ..., L-N)	Cada fila de álabes, comenzando en L-0, está representada por un estado de este nodo. Cuando se usa la red, muestra la distribución probabilística por fila, clasificando donde es más probable que ocurra el daño. Este nodo también sirve como selector para condicionar los MD. Es un nodo raíz.
Alabe_PP (hoja, cubierta, alambre, raíz)	Representa la discretización del álabe para condicionar el conjunto de MD. Cuando se usa la red, muestra la distribución probabilística, clasificando la parte/porción (PP) de la hoja donde es más probable que ocurra el daño. Padre: Alabe_Fila.
Mecanismos de daño	
Pic_MD (presente, ausente)	Picaduras de corrosión. Padres: Alabe_Fila, Alabe_PP.
Got_MD (presente, ausente)	Impacto de gotas. Padres: Alabe_Fila, Alabe_PP.
Fricc_MD (presente, ausente)	Fricción de las superficies. Alabe_Fila, Alabe_PP.
SCC_MD (presente, ausente)	Agrietamiento asistido por corrosión bajo tensión. (<i>Stress Corrosion Cracking</i>). Padres: Pic_MD, Alabe_Fila, Alabe_PP.
CF_MD (presente, ausente)	Corrosión Fatiga. Padres: Pic_MD, SCC_MD, Alabe_Fila, Alabe_PP.
Fatiga_MD (presente, ausente)	Fatiga mecánica. Padres: Got_MD, Alabe_Fila, Alabe_PP.
Modos de fallo	
Eros_MF (presente, ausente)	Fallo debido a la erosión de las gotas. Dada la definición de fallo de álabe, si se encuentra evidencia de erosión mecánica por impacto de gotas durante una inspección, pero no se toman medidas correctivas, entonces no se cuenta como fallo. Padre: Got_MD
Corr_MF (presente, ausente)	Fallo por picaduras. Dada la definición de fallo de álabe, si se encuentra evidencia de corrosión durante una inspección, pero no se toman medidas correctivas, no se cuenta como fallo. Padre: Pic_MD.
Ag/Fr_MF (presente, ausente)	Fallo debido a grietas o fracturas observadas. En contraste con los MF de erosión y corrosión, “todos los daños por grietas o indicaciones similares a grietas en los álabes de las turbinas de vapor deben repararse, pulirse (<i>blended</i>) o reemplazarse, según corresponda” [5, p. 4_9]. Por lo tanto, este nodo se modela con una compuerta OR determinista. Padres: CF_MD, SCC_MD, Fatiga_MD.
Nodo tope	
MF_Turb (forzado, programado, no_MF)	Contiene las distribuciones de probabilidad basadas en la frecuencia con la que se encuentran los MF durante las interrupciones forzadas/programadas. El estado “no_MF” es verdadero cuando sus padres están ausentes, lo que significa que no hay fallo de turbina sin un MF que la provoque. Padres: Eros_MF, Corr_MF, Ag/Fr_MF.

Como se observa en la información del modelo de RB construido (Figura 6, ecuación (40) y la descripción en la Tabla 6), existe un proceso de jerarquización de los nodos declarados. Como se discutió en el Capítulo I, las filas de álabes en la turbina pueden considerarse como poblaciones de elementos muy similares que están sometidos a las mismas condiciones ambientales y mecánicas. Sin embargo, para cualquier fila dada,

estas condiciones varían según la parte del álabe, por ejemplo, raíz, hoja, etc. Dicha dependencia está representada por el arco del nodo Alabe_Fila al nodo Alabe_PP. Dado que los MD dependen de la parte del álabe y de la fila, se trazan arcos desde Alabe_Fila y Alabe_PP a todos los nodos MD. Luego, se definen las interacciones entre los MD para cada combinación de ubicación. A su vez, estos MD causan los MF observables a nivel de álabe y en la parte superior, estos MF pueden provocar que la turbina se declare como fallada debido a los álabes en una inspección programada o bien puede dejar de funcionar inesperadamente, interrumpiendo la producción de energía.

4.4. Cuantificación de la RB

El proceso de cuantificación es estimado como un paso complejo en el proceso de construcción de una RB debido a la gran cantidad de combinaciones que existen en una TPC de un nodo con relativamente pocos padres. En esta sección se abordan los temas concernientes a las características deseadas que el método de cuantificación automático debe cumplir de acuerdo con las características del modelo cualitativo desarrollado en la sección anterior; la proposición del método de cuantificación en sí; los parámetros de entrada que se deben obtener del conocimiento experto para calcular las TPC; y la encuesta desarrollada con este fin.

4.4.1. Características deseadas para el cálculo de las TPC del modelo estático

En la sección 2.2 se han abordado la necesidad de los métodos de generación automática de probabilidades para la cuantificación de RB y se debatieron diferentes métodos existentes a partir de la opinión de expertos.

Para este modelo, se debe definir un conjunto de parámetros de tipo *leak* (ordenados como una matriz) para cada MD con el objetivo de considerar las probabilidades de que cada MD pueda ocurrir espontáneamente en cada combinación de ubicación (Alabe_PP y Alabe_Fila). Del análisis realizado en el Capítulo I, algunos MD dependen condicionalmente de otros, pero también pueden ocurrir incluso si los nodos MD padres están en sus estados ausentes. Este comportamiento se aplicó a la RB presentada en la Figura 6, donde los nodos Fricc_MD, Pic_MD y Got_MD son independientes de otros MD, por lo que estos ocurren aparentemente de forma espontánea, sin ayuda de otro MD. Fatiga_MD, SCC_MD y CF_MD dependen de los tres primeros de diferentes

maneras, pero cuando sus respectivos padres están ausentes, todavía tienen probabilidad de ocurrir. Parámetros *leak* son idóneos para cuantificar este comportamiento. Los *leak* involucran otras causas o mecanismos subyacentes más allá del alcance del modelo.

Otra característica que posee el modelo aquí tratado es que, desde el punto de vista de los álabes, la susceptibilidad de sufrir de unos u otros MD cambia, es por esta razón que se crearon dos variables de ubicación del daño, explicadas con anterioridad en la sección 4.2.3. La probabilidad de observar los MD es dependiente de las variables *Alabe_PP* y *Alabe_Fila*, las cuales poseen varios estados (no binarias) no necesariamente ordenados (ver la definición de Díez [81, p. 103] para variables ordenadas). La susceptibilidad de cada fila y parte de álabes puede tener una fuerte variación que es un reto para los métodos de interpolación, incluso por partes.

Por último, como se ha discutido en las conclusiones del Capítulo II, es deseable que el método para calcular las TPC no sea un modelo ICI, es decir, que considere una gama de valores menos restrictivos y permita sinergia para contemplar las dependencias entre los MD. Debido a esto, primero se consideró el modelo RNOR, pero en el capítulo III se desarrolló el ERNOR. Las interacciones tipo interferencia no se han encontrado en la revisión bibliográfica de los MD modelados. El rango de valores de inhibición no es necesario en este modelo de turbina dado que no se espera que la observación de más MD reduzca la probabilidad de observar uno que sea dependiente de los primeros.

Según las necesidades expuestas, el método que se requiere para el cálculo de TPC debe cumplir con los siguientes aspectos:

1. Permitir la encuesta de una cantidad razonablemente pequeña de parámetros para el posterior cómputo de grandes tablas.
2. No debe depender de métodos de interpolación porque son demasiado restrictivos para describir la susceptibilidad al daño de las filas de álabes y sus partes.
3. Debe considerar probabilidades conjuntas no restrictas por los modelos ICI, específicamente la posibilidad de introducir probabilidades conjuntas sinérgicas para modelar las influencias de los MD.

4. Cada TPC debe incluir más de un parámetro *leak* por nodo del tipo MD, para tener en cuenta las influencias no modeladas de las causas que afectan a los MD modelados explícitamente en cada combinación de ubicación.

Para alcanzar las características deseadas, se desarrolla un nuevo método de cálculo de TPC. El método, que se describe en las siguientes secciones combina el modelo ERNOR con un proceso de clasificación del nivel de susceptibilidad de las ubicaciones de la turbina a sufrir de los MD. Además del método, explicado paso a paso, en el Anexo A se presenta la encuesta desarrollada para obtener los parámetros básicos para la cuantificación a partir del juicio de expertos.

4.4.2. Pasos para calcular las TPC del modelo

Calcular las TPC es un proceso de varios pasos. En el primer paso se explican las restricciones generales que deben cumplir las tablas cuando algunas de las partes del álabe no están presente en alguna fila. Los pasos del 2 al 4 están vinculados al proceso de clasificación del nivel de susceptibilidad de las ubicaciones de la turbina a sufrir de los MD. Las influencias entre los nodos se recopilan y calculan para obtener los CPT de los nodos dependientes en los pasos del 5 al 8. Finalmente se imponen algunas restricciones a los nodos tipo MF.

En el Anexo A se presenta la encuesta completa para obtener los parámetros que se describen aquí. La misma se ha implementado en una hoja de cálculo, que realiza todos los cálculos descritos en el Anexo B para obtener las TPC finales, además de mostrar automáticamente advertencias ante las violaciones de condiciones que aquí se describen. A continuación, el subíndice i identifica el nodo de interés, por lo que MD_i es un mecanismo de daño de interés y pMD_i es su conjunto de nodos padre.

Paso 1. Cuantificación de restricciones físicas del sistema

Los nodos *Alabe_Fila* y *Alabe_PP* representan el tamaño físico del sistema y la granularidad. El nodo *Alabe_Fila* contiene una distribución probabilista uniforme respecto a la cantidad de filas de la turbina. El nodo *Alabe_PP* es también una distribución uniforme. Es de esperarse que cada fila pueda tener diferencias estructurales con sus vecinas. De acuerdo con la discretización que se aplica en este modelo para los álabes (Figura 5B), las diferencias radican en si poseen alambres de amarre y cubiertas, dado

que todos los álabe tienen raíces y hojas. Estas diferencias se tienen en cuenta desde el inicio conociendo el diseño o pueden preguntarse al experto. Con este propósito, en la encuesta dicha información se recaba en una tabla poniendo un 0 en las celdas correspondientes a las partes/porciones del álabe que no existen en las filas, y un 1 cuando sí existen. La Tabla 7 es un ejemplo de TPC del nodo Alabe_PP, cuando los alambres sólo están presentes en las filas L-0 y L-1.

Tabla 7: Representación del nodo Alabe_PP y sus restricciones

A.part/fila	L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8
Hoja	0.25	0.25	1/3	1/3	1/3	1/3	1/3	1/3	1/3
Cubierta	0.25	0.25	1/3	1/3	1/3	1/3	1/3	1/3	1/3
Alambre	0.25	0.25	0	0	0	0	0	0	0
Raíz	0.25	0.25	1/3	1/3	1/3	1/3	1/3	1/3	1/3

La repercusión de esta restricción en el nodo Alabe_PP para el resto de los nodos se expone en el paso 4.

Paso 2. Construcción de las Matrices leak

El proceso de clasificación de la susceptibilidad de la ubicación (por fila y parte del álabe) a sufrir del MD_i se consulta en la encuesta con dos tablas, una para las filas y otra para la discretización del álabe. Se le pide al experto que clasifique esta susceptibilidad en un rango de 0 a 10, siendo 0 la imposibilidad de que el MD_i se desarrolle en la ubicación (p.ej., porque el diseño ha demostrado que la ubicación es inmune al MD o actúa de forma insignificante). Se sugiere al experto no usar 0 si cree que el MD_i puede ocurrir, incluso si personalmente no lo ha observado. Un valor de 10 aplica a la ubicación más susceptible, y debe haber al menos un 10 en cada tabla, para las filas y las partes del álabe. En cada tabla, es posible que el experto pueda definir más de una ubicación con el valor 10.

Paso 3: Encuesta del Factor leak

Otro valor se consulta en la encuesta con una pregunta en la forma: “Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en la tabla de Alabe_Fila y la de Alabe_PP), ¿cuál es la proporción de veces que ha observado o

espera observar [el nombre del MD_i de interés] sin influencia de [todos los pMD_i] cuando la turbina es inspeccionada?”. Por conveniencia, el valor encuestado se denomina factor *leak* (FL_i) del nodo MD_i porque se usará en el paso 4 para calcular los *leaks* dependientes de la ubicación en la TPC. El objetivo de esta pregunta es obtener el porcentaje de veces que el MD_i se observa espontáneamente (todos los pMD_i explícitos están ausentes o el nodo carece de ellos) en las ubicaciones más susceptibles.

Paso 4: Cálculo de la matriz leak

Para cada MD_i , las tablas correspondientes del paso 2 se multiplican valor a valor y se dividen por 100 para obtener una matriz en el rango de las probabilidades (0 a 1), llamada matriz de susceptibilidad para el mecanismo (MS_i), con celdas $MS_{i,j,k}$, siendo $j = \{hoja, cubierta, alambre, raíz\}$ y $k = \{L0, \dots, Ln\}$ son las filas de álabes (ver Figura 7). Los valores $MS_{i,j,k}$ correspondientes al nodo MD_i se combinan con su FL_i para obtener la matriz de *leaks* ($P.leak_i$), por lo que sus celdas se calculan como:

$$P.leak_{i,j,k} = SM_{i,j,k} * FL_i \tag{41}$$

Note que se genera la matriz de *leaks* estableciendo un rango dependiente de la ubicación desde el valor de probabilidad superior que el experto proporciona como el *leak* más alto (LF), hasta cero. Para un nodo, su matriz de *leaks* se completa con sólo tres preguntas: una para las filas, una para las PP de los álabes y otra para el FL , independientemente del tamaño de la turbina. La Figura 7 muestra el proceso para calcular las matrices de *leaks* con un ejemplo numérico, en el cual, los datos de entrada son las tablas de la esquina superior izquierda y el factor *leak* debajo de ellas. Las probabilidades calculadas implican que las hojas de L-0 a L-2 son las más susceptibles al MD_i en cuestión, o que es más probable que el daño se encuentre en esas ubicaciones, también hay un 10% ($FL_i = 0.10$) de probabilidad de encontrar ese daño “solo” sin la presencia de los pMD_i , cuando se inspecciona la turbina. Las celdas sombreadas en la figura pertenecen a probabilidades imposibles: en este caso, los alambres solo están presentes en L-0 y L-1, información obtenida del paso1.

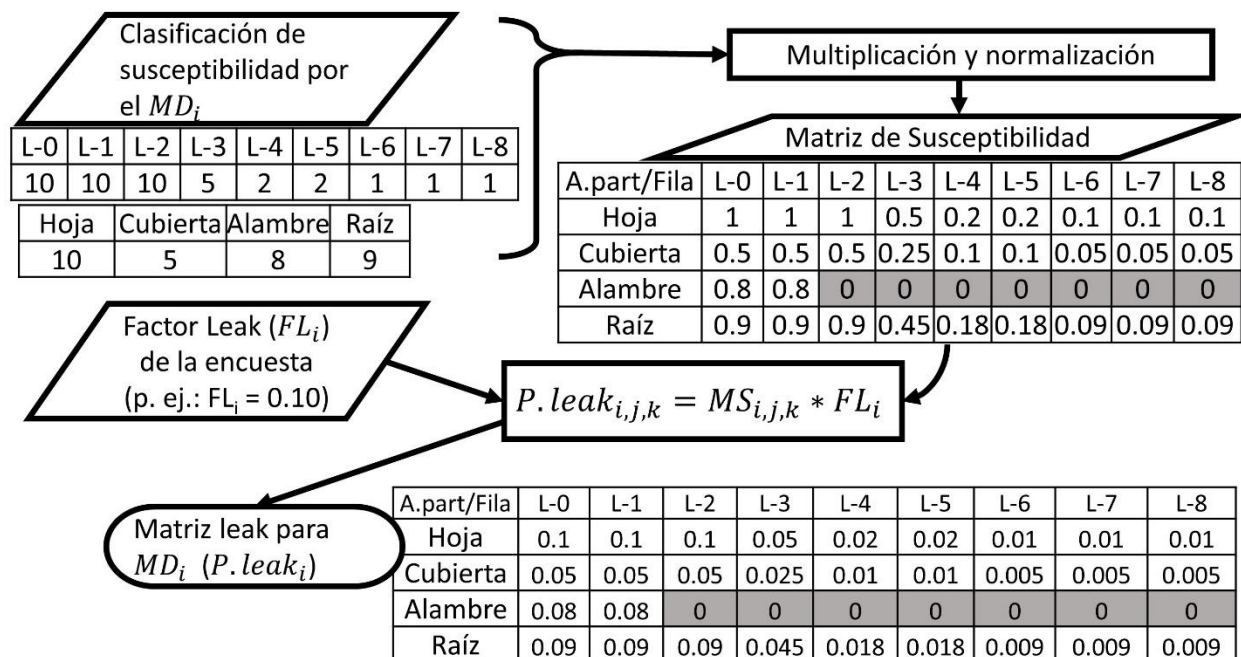


Figura 7: Cálculo de la matriz leak para un MD. Pasos del 1 al 4

Los pasos anteriores son los necesarios para los nodos Pic_MD, Got_MD y Fricc_MD, los cuales no poseen otros MD como padres, sólo los nodos de ubicación, por lo que la pregunta tipo del paso 3, para estos nodos, no necesita la aparte “...sin influencia de [todos los pMD_i]...”

Paso 5. Encuesta de las probabilidades de influencia independiente y conjuntas

Para los nodos que poseen otros MD como padres, como SCC_MD, CF_MD y Fatiga_MD, el procedimiento es más complejo porque sus TPC contemplan las matrices leak, $P(MD_i = presente | todos pMD_i = ausente)$ más $P(MD_i = presente | C_{1,2,...,n}^n\{pMD_i\} = presente)$, donde $C_{1,2,...,n}^n\{pMD_i\} = presente$ son las combinaciones del conjunto de padres del MD_i que se encuentran en estado presente. Los siguientes conceptos se aplican a estos casos:

El término “influencia” en este contexto significa que uno o varios MD pueden causar directamente, servir como iniciadores o potenciadores o, en general, acelerar el proceso de evolución de otro mecanismo de daño dependiente (MD_i). Tal influencia conduce a un aumento en la probabilidad de ocurrencia del mecanismo de daño dependiente.

Probabilidad de influencia independiente (PII): es el efecto de solo un MD sobre otro. Por ejemplo, “X aumenta la probabilidad de ocurrencia de Z en un 10%”, lo que equivale a decir: “la probabilidad de influencia independiente de X sobre Z es del 10%.”

Probabilidad de influencia conjunta (PIC): es el efecto de dos o más MD sobre otro. Por ejemplo, “X e Y conjuntamente aumentan la probabilidad de ocurrencia de Z en un 25%”, lo que equivale a decir: “la probabilidad de influencia conjunta de X e Y sobre Z es del 25%.”

Con los conceptos anteriores, en este paso se consultan el conjunto de PII_i y PIC_i que ejercen las diferentes combinaciones de pMD_i sobre cada MD_i dependiente.

Los PII se encuestan con una pregunta como: “¿Cuál es la probabilidad de influencia independiente de [un padre específico del conjunto pMD_i] sobre [el MD_i], descartando la influencia de [los padres restantes del conjunto pMD_i] y de otros posibles factores no modelados?”

Los PIC se encuestan como: “¿Cuál es la probabilidad de influencia conjunta de [una combinación específica de padres del conjunto pMD_i] sobre [el MD_i], descartando la influencia de [los padres restantes del conjunto pMD_i no considerados en la combinación anterior] y de otros posibles factores de influencia no modelados?”

Paso 6. Cálculo de las probabilidades de influencia conjuntas faltantes

El cálculo de las restantes PIC que corresponden a las combinaciones de pMD_i que no ha sido posible encuestar directamente a los expertos, se efectúa mediante la ecuación (30), correspondiente al modelo ERNOR. Como ejemplo, se presenta la expresión que tiene la PIC de tercer orden que ejercen los nodos Pic_MD, SCC_MD y Fricc_MD simultáneamente sobre el nodo CF_MD:

$$\begin{aligned}
 & PIC_{CF_MD}^{ERNOR} | Pic_MD, SCC_MD, Fricc_MD \\
 &= 1 - \frac{[1 - PIC_{Pic_MD, SCC_MD}^{E/ERNOR}] * [1 - PIC_{Pic_MD, Fricc_MD}^{E/ERNOR}] * [1 - PIC_{SCC_MD, Fricc_MD}^{E/ERNOR}]}{[1 - PII_{Pic_MD}^E] * [1 - PII_{SCC_MD}^E] * [1 - PII_{Fricc_MD}^E]} \quad (42)
 \end{aligned}$$

Los super índices con “E/ERNOR” implican que los valores correspondientes pueden provenir de un experto (E) o ser calculados por el ERNOR.

Paso 7. Combinación de leaks con probabilidades de influencia

En este paso se calculan los estados presentes de un nodo MD_i siendo influenciado por sus padres correspondientes pMD_i a través de las PII y PIC, teniendo en cuenta las variables de ubicación Alabe_PP (subíndice j) y Alabe_Fila (subíndice k).

$$\begin{aligned}
 & P(MD_{i,j,k} | pDM_{i,j,k}, Alabe_PP_j, Alabe_Fila_k) \\
 &= \begin{cases} 1 - [1 - PI_{C_{1,2,\dots,n}\{pMD_i\}}^{E/ERNOR}] * [1 - P.leak_{i,j,k}] & \text{si A} \\ 0 & \text{si no} \end{cases} \quad (43)
 \end{aligned}$$

La ecuación (43) expresa la forma de combinar la matriz de valores *leak* con las probabilidades de influencia (PI), ya sean PII o PIC según la cantidad de causas de la combinación que se esté calculando. La condición A se compone de dos condiciones: A1 y A2. La condición A1 implica que la matriz de salida de la expresión (43) es la combinación de la PI para cierta combinación de padres, combinada con los valores *leak* para cada ubicación, siempre que el valor proporcionado por el experto para dicha combinación de padres no sea cero, es decir: $PI_{C_{1,2,\dots,n}\{pMD_i\}}^E \neq 0$, de lo contrario, toda la matriz tiene valores iguales a cero. Note que la expresión superior de (43) es la expresión (4) con diferentes nombres en sus variables, y extendida para tratar múltiples *leaks* en forma matricial.

La condición A2 implica que debe cumplirse la causalidad positiva. A2 es, de hecho, un conjunto de reglas lógicas que comparan los valores proporcionados por el experto para combinaciones inferiores y los calculados mediante la ecuación del ERNOR (30), asegurando la causalidad positiva. Si no se logra la causalidad positiva en una PI, se advierte al experto sobre el valor fuera de rango y debe cambiarlo. En el modelo de RB discutido en este capítulo, el orden más alto es tres y las combinaciones de segundo

orden se monitorean para asegurar la causalidad positiva del tercer orden de combinaciones.

Paso 8. Estructuración de las TPC

La TPC para los nodos independientes de otros MD se obtiene a partir de la matriz de *leaks* solamente, y la matriz de *leaks* más las matrices resultantes de la expresión (43) para aquellos que son dependientes de otros MD. Cualquiera sea el caso, ha de tenerse en cuenta que las matrices se refieren a los estados presentes de los MD y deben organizarse en el formato TPC deseado, dependiendo del software de RB que se utilice, considerando también los estados ausentes, que son complementos de los presentes $P(MD_i = ausente) = 1 - P(MD_i = presente)$.

En la Figura 8 se representa un diagrama de flujo para los pasos 5 a 7. El proceso comienza con los PI del cuestionario (arriba a la izquierda) y la matriz de *leaks* (arriba a la derecha) provenientes del paso 4. Para este ejemplo, la matriz de *leaks* de la Figura 7 es usada. Los PI no proporcionados por el experto se calculan mediante la ecuación ERNOR (30), y las reglas de la ecuación (43) son aplicadas para combinar la matriz *leak* con las probabilidades de influencia. De esta manera, las celdas de las TPC se calculan en la hoja de cálculo, o aparece una advertencia al experto sobre una violación de la causalidad positiva, pidiéndole que reconsidere los valores fuera de rango. Las matrices resultantes, listas para ser reestructuradas para conformar una TPC, se muestran dentro del recuadro punteado.

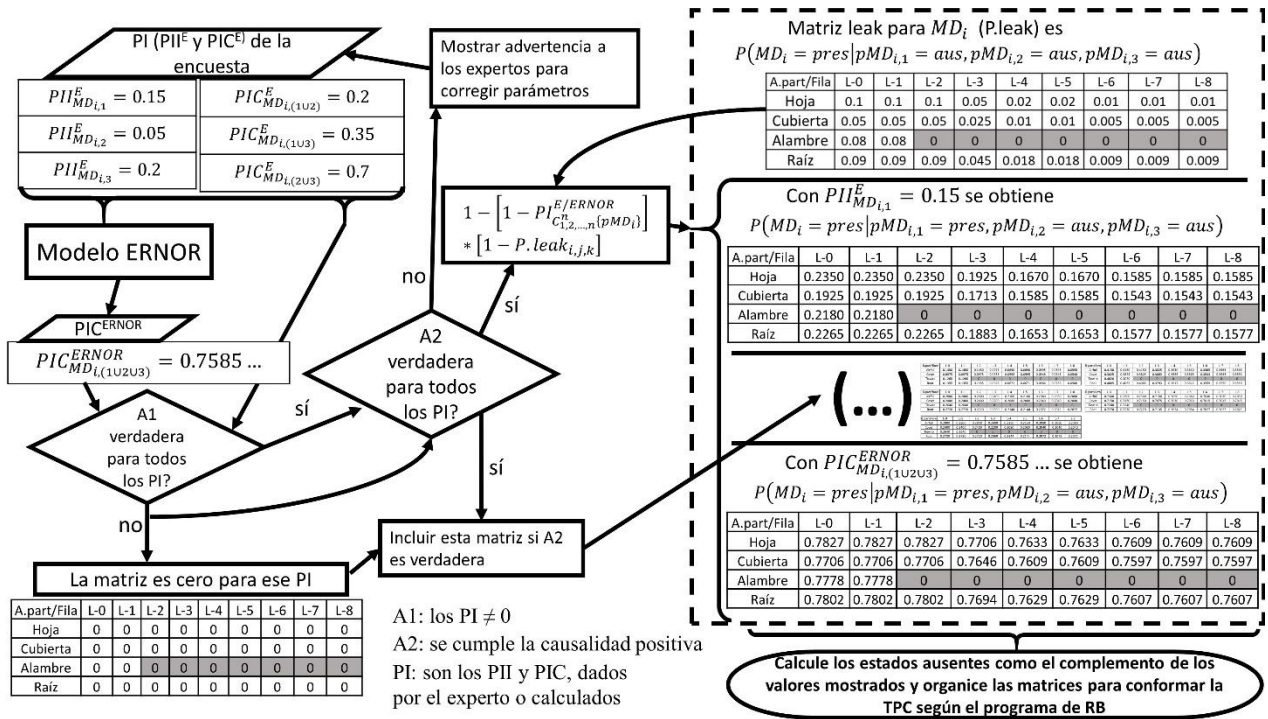


Figura 8: Cálculo de las TPC. Pasos del 5 al 8

Paso 9. Cuantificación de los nodos tipo MF

Ya se han expuesto los pasos necesarios para cuantificar los nodos tipo MD, los cuales constituyen el nuevo método de cuantificación para generar las TPC. En este paso se exponen las consideraciones finales para los estados de los nodos que no son MD, como los MF.

Existen dos asunciones para los nodos tipo MF. La primera se expresa como $P(Corr_{MF} = ausente | Pit_{MD} = ausente) = 1$ y $P(Eros_{MF} = ausente | Droplet_{MD} = ausente) = 1$. La primera expresión asume que el MF por corrosión se produce solo por picadura, por lo que, si hay 100% de certeza de que no hay picaduras, entonces hay 100% de certeza de que no existe el MF por corrosión. La misma lógica se aplica para el MF de erosión que solo se produce por el impacto de gotas.

Los valores positivos de estos MF por corrosión y erosión se consultan al experto con una pregunta del tipo “De su estimado de la proporción de las veces que una acción correctiva se ejecuta en los álabes dado que, en una inspección de turbina, es observado el [MD_i]”.

Los valores del nodo que MF_Turb se obtienen mediante una tabla en la que el experto estima la frecuencia con la que se observa o espera observar cada MF modelado en paradas forzadas o programadas. Su restricción es $P [MF_Turb = no_MF | (Corr_MF, Ag/ Fr_MF, Eros_MF) = ausente] = 1$. En otras palabras, si no se produce un MF del álabe, entonces no es posible que se produzca un fallo de turbina debido al fallo de los álabes.

Las restricciones anteriormente mencionadas se encuentran parafraseadas en las correspondientes descripciones de los nodos presentadas en la Tabla 6.

4.4.3. Datos

Para analizar una sola turbina instalada en una instalación específica, los expertos deben tener conocimientos sobre el sistema: estar familiarizados con las especificaciones de operación, problemas técnicos, historial y tareas de mantenimiento. El experto ideal para proporcionar la información requerida en la encuesta para una turbina específica trabaja directamente en el mantenimiento o la operación de la turbina. El personal de una empresa fabricante o de mantenimiento de turbo maquinaria debe poder aportar su experiencia para más de un modelo de turbina, es probable que tenga conociendo del comportamiento de una flota de turbinas instaladas en diferentes plantas, ya que habitualmente almacenan esta información en sus bases de datos. Por ello, el número de expertos es escaso y con poca variabilidad. En los Análisis Probabilísticos de Riesgo los criterios usados en la toma de decisiones informada en el riesgo se basan en valores promedio [101], por lo que seguimos los mismos criterios con respecto a la agregación de los valores puntuales proporcionados por varios expertos para el cálculo de los valores de las TPC según el método descrito.

Una RB para el peor de los casos (mayor riesgo) se puede cuantificar utilizando los valores máximos proporcionados por varios expertos en cada pregunta. El utilizar los valores máximos puede considerarse como un límite superior de la variabilidad del juicio de expertos, el caso más pesimista. Asimismo, el mejor escenario (menor riesgo) se calcula utilizando los valores mínimos de cada pregunta. Los tres modelos de RB (peor caso, medio y mejor caso) son importantes en un proceso de toma de decisiones.

El juicio de expertos se recopiló a través de un cuestionario que aplica el tipo de preguntas mencionadas en los pasos anteriores. Para evitar que los expertos violen la causalidad positiva, el cuestionario se construyó en una hoja de cálculo que permite la introducción de reglas lógicas que actualizan automáticamente los rangos válidos de las PI que el experto puede proporcionar y advierte sobre errores o valores fuera de rango. La versión textual encuesta se presenta en el Anexo A.

A medida que se disponga de más datos de fallas de turbinas de la planta, o si se dispone de datos de turbinas similares, las TPC calculadas inicialmente con el método presentado pueden actualizarse con la nueva información, mejorando su precisión, utilizando el algoritmo de aprendizaje llamado estimación-maximización (*estimation maximization learning: EM*) [102]. La información necesaria de los fallos para el proceso de aprendizaje por EM debe coincidir con los nodos de la RB: el tipo de MF descubierto (agrietamiento o fractura, erosión y corrosión), los MD involucrados en el desarrollo del MF, el lugar del álabe que falla, la fila y el tipo de inspección que permitió identificar el daño (forzado o programado). Estos datos podrían recopilarse a partir de informes de inspección y análisis de causa raíz.

4.5. Validación

La validación del modelo desarrollado en la RB se realiza comparando el comportamiento del modelo con tres axiomas propuestos por Jones *et al.* [103]. Este procedimiento nos permite determinar si los resultados del modelo concuerdan con los datos de entrada. Dichos axiomas han sido ampliamente utilizados con este propósito por variedad de autores de modelos causales, aplicándolos a los contextos específicos de cada modelo. Los datos que se muestran en la Tabla 8 se utilizan en esta sección y en la siguiente, a menos que se indique lo contrario. Los datos corresponden al juicio de expertos sobre una turbina de vapor nuclear de baja presión, que consta de nueve filas de álabes con alambres de unión solo en L-0 y L-1.

Tabla 8: Datos de entrada para el modelo de RB

Fila de álabes y Parte/Porción	Pic_MD	Got_MD	Fricc_MD	SCC_MD	Fatiga_MD	CF_MD
L-0	10	10	10	10	1	10
L-1	10	9	10	9	2	10
L-2	9	7	10	9	3	10
L-3	9	4	10	8	4	5
L-4	5	1	10	8	8	2
L-5	1	1	10	1	8	2
L-6	1	1	10	1	10	1
L-7	1	0	10	0	10	1
L-8	1	0	10	0	10	1
Hoja	10	10	0	8	10	10
Cubierta	6	8	0	5	3	5
Alambre	1	3	8	8	8	8
Raíz	1	1	10	10	10	9
Factor leak (FL)	0.10	0.20	0.05	0.15	0.15	0.10
Probabilidades de influencia (PI)	No aplica			$PII_{(SCC Pic)}^E = 0.20$ $PII_{(SCC Fricc)}^E = 0.35$ $PIC_{(SCC Pic,Fricc)}^E = 0.60$	$PII_{(Fat Got)}^E = 0.40$ $PII_{(Fat Fricc)}^E = 0.10$ $PIC_{(Fat Got,Fricc)}^E = 0.65$	$PII_{(CF Pic)}^E = 0.15$ $PII_{(CF SCC)}^E = 0.05$ $PII_{(CF Fricc)}^E = 0.20$ $PIC_{CF Pic,SCC}^E = 0.20$ $PIC_{CF Pic,Fricc}^E = 0.35$ $PIC_{CF SCC,Fricc}^E = 0.70$ $PIC_{(CF Pic,SCC,Fricc)}^{ERNOR} = 0.7585$

Los axiomas son los siguientes:

1. Un ligero aumento/disminución en las probabilidades *prior* de los nodos padres (inserción de evidencia) debería resultar en un aumento/disminución de las probabilidades posteriores de los nodos hijos.
2. Una variación de las distribuciones de probabilidad de los nodos padres (variación de la distribución probabilística de los estados) debería tener una influencia consistente en los nodos hijos.
3. La magnitud total de la influencia que ejerce una variación simultánea de un conjunto X de padres (variación insertada como evidencia) sobre los nodos hijos, nunca debe ser menor que la magnitud que ejerce una variación simultánea de un subconjunto Y ($Y \in X$) de padres (sub-evidencia).

En el modelo descrito, un cambio en un valor de entrada de los nodos de la Tabla 8 provoca un cambio en su TPC correspondiente. Este cambio de TPC, aplicado a los nodos padres de una RB, es percibido por los nodos dependientes como un cambio en las probabilidades *prior* de los padres. Siguiendo esa lógica, se realiza un análisis de sensibilidad aumentando los *FL* de los nodos padres, lo que nos permite verificar los axiomas 1 y 2 como se explica en los siguientes párrafos.

En la Figura 9, las probabilidades mostradas se obtienen condicionando la parte/porción del álabe a la raíz y la fila a L-0, sin establecer otra evidencia en la RB, lo cual significa que las barras que se muestran son las probabilidades *prior* para la ubicación especificada. Las barras blancas corresponden a las probabilidades *prior* de SCC_MD, CF_MD y Fatiga_MD cuando los nodos Pic_MD, Fricc_MD y Got_MD tienen sus TPC originales calculados a partir de los valores de la Tabla 8. La serie “TPC cambio 1” corresponde nuevamente a los nodos SCC_MD, CF_MD y Fatiga_MD, sumando al *FL* de los nodos padres Pit_MD, Fret_MD y Droplet_MD, 0.05 unidades (5 puntos porcentuales). La serie “TPC cambio 2” muestra los resultados cuando se suma 0,1 a los *FL* originales (10 puntos porcentuales).

Como se muestra en la Figura 9, tales cambios leves son bien captados por el modelo y se propagan a las probabilidades *prior* de los nodos hijos, aumentando ligeramente sus probabilidades, en este caso, para las raíces de L-0, confirmando que el modelo cumple con los axiomas 1 y 2. Otros aumentos o disminuciones en los *FL* tienen efectos consistentes en los nodos dependientes. La afirmación se sostiene para otras ubicaciones y otros aumentos o disminuciones en la susceptibilidad de los MD, sin embargo, no resulta práctico presentar en este informe los análisis para todas las combinaciones de ubicación.

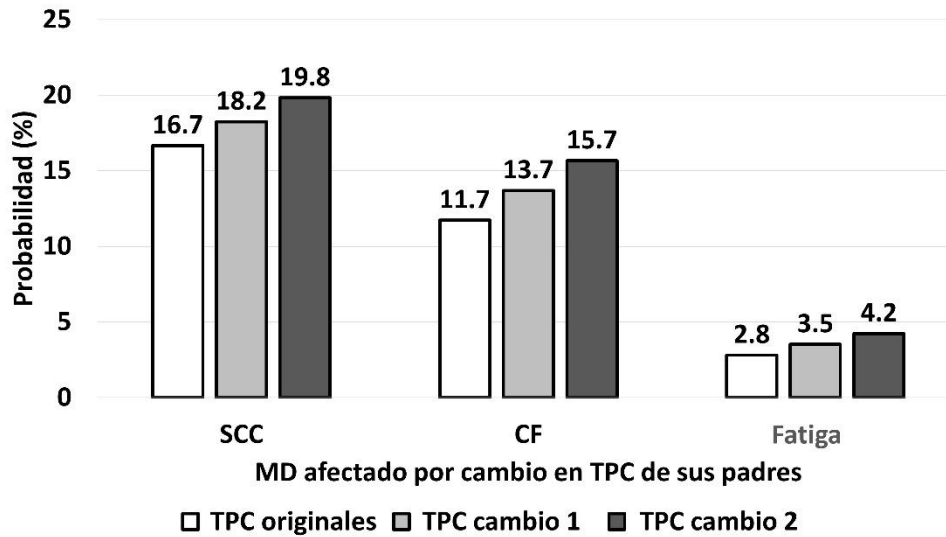


Figura 9: Efecto de la variación de las probabilidades *prior* y TPC de los nodos padre. Análisis para las raíces de la fila L-0.

Para evaluar la exactitud del modelo al describir la magnitud de las influencias entre los MD, las probabilidades de influencia independiente y conjunta, como se describe en el tercer axioma, en cada MD se introduce evidencia fuerte (*hard evidence*), es decir, insertar la evidencia al 100%. La Figura 10 presenta las probabilidades posteriores de los MD siguientes: SCC, Fatiga y CF en las raíces de L-0. Como se muestra, establecer la evidencia de un pMD en 100% aumenta la probabilidad del MD que es condicionalmente dependiente. Por ejemplo, $P(CF|Pic) > P(CF)$, y esta probabilidad aumenta si se agrega otro pMD a la combinación anterior: $P(CF|Pic, Fricc) > P(CF|Pic)$ y que $P(CF|Fricc)$; también $P(CF|Pic, SCC) > P(CF|Pic)$ y que $P(CF|SCC)$, en correspondencia con las magnitudes de las PI de la Tabla 8, cuando se combinan con los *leaks* según (43). El análisis presentado en la Figura 10 permite concluir que el modelo de RB y su cuantificación cumplen con el axioma 3.

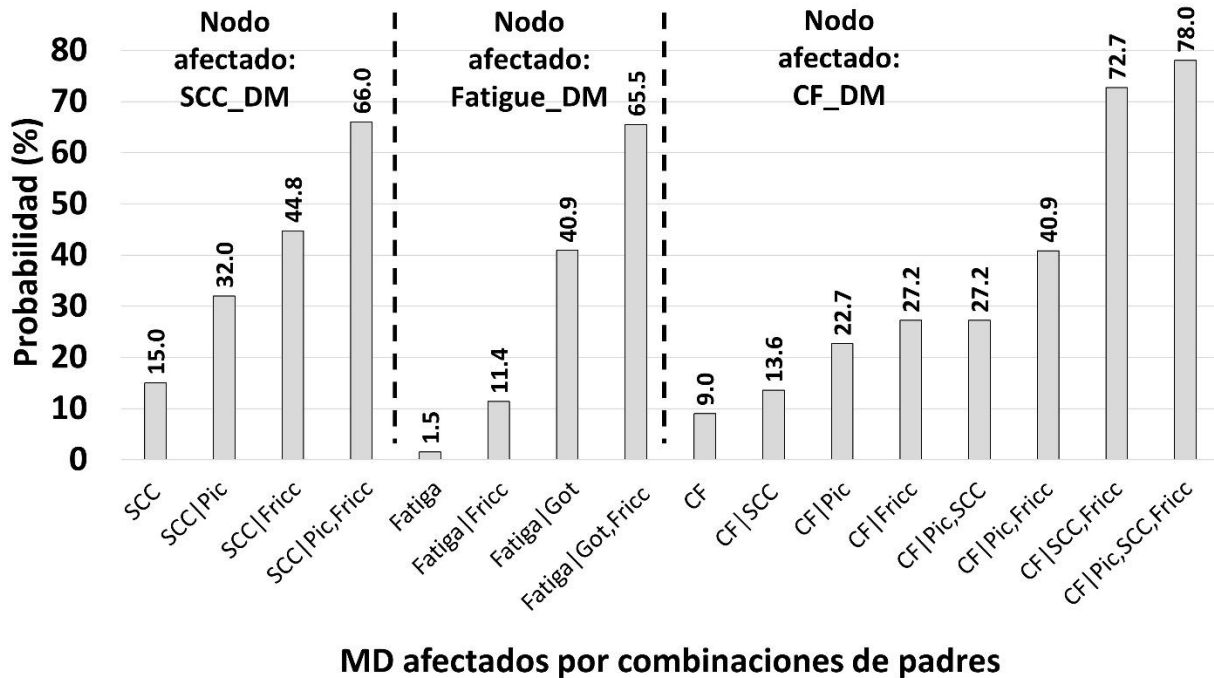


Figura 10: Efecto de las probabilidades de influencia en los nodos SCC_MD, Fatiga_MD y CF_MD para combinaciones seleccionadas de padres en las raíces de la fila L-0.

De esta forma, se concluye que el modelo concuerda con el comportamiento esperado según los análisis de sensibilidad presentados, por lo que se procede a mostrar, en la siguiente sección, los tipos de análisis que pueden realizarse con la RB y cómo ciertamente se obtiene un mejor entendimiento de las causas de los fallos.

4.6. Uso del modelo y resultados cuantitativos

El objetivo de usar la RB es realizar razonamientos a partir de la propagación de las probabilidades que se calcula a través de su estructura cuando nueva evidencia es introducida en ciertos nodos. La evidencia puede provenir de observaciones directas del estado de daño de la turbina o bien pueden basarse en hipótesis, suposiciones que hace el analista con el fin de evaluar las probabilidades posteriores de las variables y su variación, comparar escenarios y llegar a conclusiones que pueden ser utilizadas para informar las posteriores actividades de mantenimiento.

Por ejemplo, si el analista asume, hipotéticamente, una grieta causada por CF en presencia de picaduras y la ausencia de cualquier otro MD, puede pensar que la

ubicación del fallo sería más probable en L-0 y L1, con base en la Tabla 8 debido a los valores de susceptibilidad de 10 para Pic_MD y CF_MD en cada una de esas filas. Sin embargo, al introducir la evidencia en el modelo, el resultado es que la probabilidad más alta para esta combinación de daño estaría en L-2 (con 22%), seguido de L-3 (20%), luego L-0 y L-1 (19% cada uno). También es más probable que la grieta se encuentre en las hojas de los álabes (58%). La Figura 11 muestra los resultados en formato de monitor, donde los nodos son representados con recuadros que albergan en su interior el histograma de probabilidades conformado por los correspondientes estados.

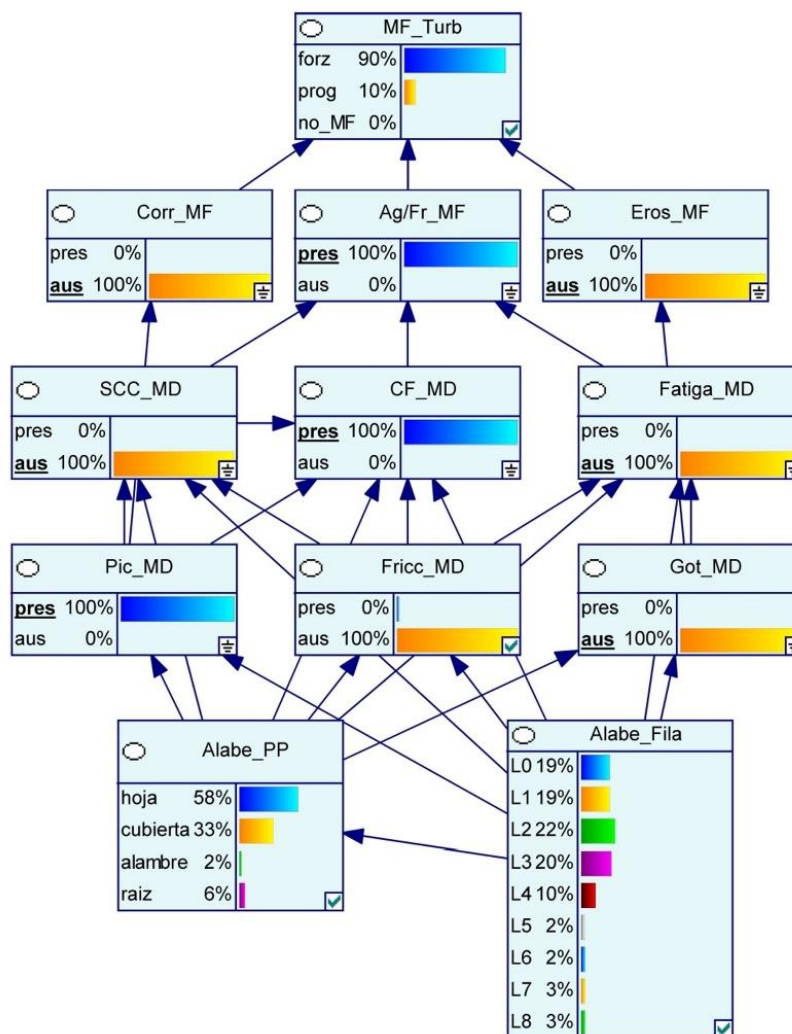


Figura 11: Estimación de las ubicaciones más propensas a sufrir de agrietamiento por CF influenciado por picaduras. Vista de nodos en monitores creada en GeNie.

Si en una inspección, la evidencia hipotética se torna cierta (observada) para alguna de estas ubicaciones propensas (suponga que falla L-0), entonces con base en el análisis realizado y la distribución del nodo Alabe_Fila, se puede recomendar la estrategia de realizar acciones preventivas contra picaduras y CF para las filas que no han fallado en el conjunto de L-1 a L-3 y posiblemente también L-4. Estas filas poseen valores de probabilidad relativamente altos en comparación con el resto de la turbina, corriendo el riesgo de fallar por las mismas causas en poco tiempo si no se toman acciones.

La Tabla 9 contiene ejemplos de conjuntos de evidencia (CEV). Los CEV son usados en los siguientes análisis para mostrar el uso e interpretación del modelo. Los números en negrita representan evidencia ingresada manualmente, los demás representan probabilidades posteriores de los nodos calculadas por la propagación de la evidencia.

Tabla 9: Conjuntos de evidencia.

Nodo	Estado	CEV1	CEV2	CEV3
MF_Turb	forzado, programado, no_MF	90/10/0	0/100/0	0/100/0
Corr_MF	Presente (ausente es el complemento)	0	62	41
Ag/Fr_MF		100	39	48
Eros_MF		0	6	27
Pic_MD		0	100	100
Got_MD		0	22	100
Fricc_MD		0	0	0
SCC_MD		63	23	21
CF_MD		41	19	17
Fatiga_MD		6	7	29
Alabe_Parte/ Porción	hoja/cubierta/ alambre/raíz	0/0/0/100	100/0/0/0	100/0/0/0
Alabe_Fila	L-0/L-1/L-2/ L-3/L-4/L-5/ L-6/L-7/L-8	100/0/0/0/0/ 0/0/0/0	100/0/0/0/0/ 0/0/0/0	100/0/0/0/0/ 0/0/0/0

Un especialista en mantenimiento puede utilizar el modelo para analizar las causas más probables de un fallo. Suponga que el modelo se usa para analizar qué MD es más probable que sea la causa de agrietamiento o fractura (Ag/Fr_MF) en la raíz del álabe,

realizando el análisis para cada fila. CEV1 representa la evidencia introducida para L-0 asumiendo la ausencia de Pic_MD, Got_MD y Fricc_MD. La Figura 12A muestra los resultados de CEV1, no solamente para L-0, sino también mostrando las restantes filas de álabes. Como se muestra, el SCC es la causa más probable de L-0 a L-3, mientras que la CF es la segunda causa más probable. Para ambos, sus probabilidades disminuyen a medida se recorre el gráfico hacia la derecha (parte frontal de la turbina). Lo contrario ocurre en el caso de la fatiga, que tiene una baja probabilidad de ser la causa del fallo en L-0 pero después de L-4, se convierte en la causa dominante.

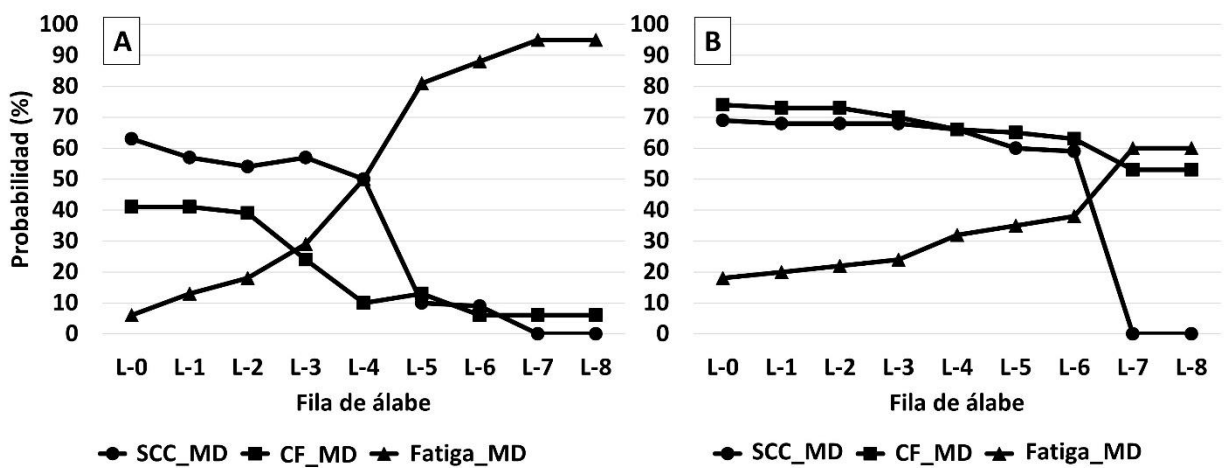


Figura 12: (A) Mecanismos de daño que provocan Ag/Fr_MF en las raíces con los demás MD ausentes. (B) *Ídem* con Fricc_MD presente.

En la Figura 12A, la variación de probabilidad de los MD representados no es estrictamente monótona, como lo demuestra el pequeño aumento de SCC en L-3, y de CF en L-5, mientras que sus clasificaciones de susceptibilidad en la Tabla 8 son monótonas. La justificación de tal comportamiento proviene del efecto “*explaining away*”, que parafraseando a Pearl [44], es cuando la observación de una consecuencia común de un conjunto de causas hace que esas causas sean dependientes; así, si una causa explica mejor el efecto, las otras tienden a reducir su probabilidad de explicarlo. La evidencia en el nodo Ag/Fr_MF es la consecuencia común. Pasando de L-2 a L-3, los valores de susceptibilidad al SCC en la Tabla 8 van disminuyendo lentamente (9 a 8) mientras que la fatiga aumenta lentamente (3 a 4) y existe una disminución repentina para CF (de 10 a 5). Esa disminución repentina de la CF induce a SCC a aumentar su

probabilidad a pesar del aumento natural del mecanismo fatiga. El aumento de CF en L-5 se debe a otra reducción abrupta en la susceptibilidad, pero esta vez de SCC (8 a 1), lo que aumenta ligeramente la probabilidad de CF. El análisis realizado demuestra, además de lo antedicho en la sección de validación, que el modelo se comporta de forma correcta, proporcionando una mayor comprensión gracias a la consideración de las dependencias probabilísticas entre los MD, mejorando la comprensión de los fenómenos que inducen el fallo.

La Figura 12B presenta el caso cuando se agrega evidencia de la presencia de Fricc_MD a la evidencia utilizada para construir la Figura 12A, como puede ocurrir cuando surge nueva evidencia durante una inspección de turbina. Las indicaciones de fricción hacen que SCC aumente en probabilidad, sin embargo, CF es ahora la causa más probable del fallo, debido a una probabilidad de influencia más alta por parte de sus padres (la probabilidad conjunta de SCC y Fricción, en la cual SCC ha tomado mayor importancia en su contribución a CF, ver Tabla 8). La fatiga es la causa más probable, pero solo para L-7 y L-8, y con una probabilidad menor que en la Figura 12A, porque la influencia de la fricción sobre la fatiga es menor que la influencia de la fricción sobre CF y SCC.

En el CEV2 se asume que, en una interrupción programada, se descubre la presencia de picaduras en las hojas de la fila de álabes L-0. Esta evidencia fuerte se introduce en la RB mientras que el resto de los nodos toman sus probabilidades posteriores para evaluar el efecto. Dadas estas condiciones, la probabilidad de tener Corr_MF es del 62%, lo que lo convierte en el MF más probable, comprensiblemente dada la influencia directa de su padre Pic_MD. existe un 39% de probabilidad de Ag/Fr_MF, dadas las probabilidades posteriores de sus nodos padres, SCC, CF y Fatiga, que son de 23, 19 y 7%, respectivamente. Esto implica que SCC es el mecanismo de daño más probable que conduce a Ag/Fr_MF en el contexto de CEV2.

CEV3 se basa en CEV2 al agregar evidencia de impacto de gotas, otro hallazgo potencial durante una inspección programada. Con esta nueva evidencia, Ag/Fr_MF se convierte en el más probable con 48% contra 41% para Corr_MF y 27% para Eros_MF. Es un aumento en Fatiga_MD, como resultado de la presencia de su padre Got_MD, la causa de una mayor probabilidad en Ag/Fr_MF. Este ejemplo muestra cómo se pueden

incorporar nuevas evidencias en el modelo, cambiando nuestras creencias sobre el resto de los nodos afectados, y que, incluso con variables inciertas, se obtienen resultados.

4.7. Contribuciones del modelo de RB para evaluar los MD en turbinas

Los ejemplos presentados en la sección anterior demuestran el valor de uso del modelo desarrollado, que permite codificar todas las piezas de información aparentemente independientes que un experto puede tener en mente, en un único modelo compacto de RB a través de la metodología presentada. La RB permite preservar el conocimiento, permitiendo a otras personas, o incluso el mismo experto, realizar diferentes ejercicios de razonamiento y descubrir detalles que pueden no ser detectados por otros medios. Uno de los beneficios de este modelo es que un experto puede responder el cuestionario y ejecutar el modelo para ver su conocimiento mostrado gráficamente, usándolo para probar conjuntos de hipótesis sobre los MD, fallos y ubicaciones, obteniendo conocimiento antes de que ocurra un fallo, o para introducir directamente como evidencia las indicaciones de daño observadas durante las inspecciones.

Como resultado, las principales contribuciones científicas pueden agruparse en dos áreas fundamentales: la contribución al proceso de mantenimiento, en el sentido en que el modelo ofrece una mayor granularidad para determinar los mecanismos responsables de los fallos y las ubicaciones propensas, resultando en información más detallada y útil para la toma de decisiones en el proceso de mantenimiento; y el novedoso proceso de cuantificación de TPC para las RB. Ambos aspectos se abordan a continuación.

4.7.1. Contribuciones para el campo de mantenimiento en turbinas

Desde la perspectiva del mantenimiento, el modelo desarrollado con RB no pretende reemplazar los métodos y técnicas utilizados para identificar daños, sino que es una herramienta analítica que busca complementarlos en la fase de identificación de los MD.

El modelo de RB proporciona información y detalles adicionales para informar mejor los procesos de planificación y ejecución del mantenimiento, mediante la identificación de los mecanismos de daños subyacentes asociados con las fallas. La red recibe evidencia obtenida de observaciones visuales por diferentes técnicas y luego proporciona información en la forma de probabilidades posteriores mediante la propagación de la

evidencia que se puede utilizar para informar los siguientes pasos de mantenimiento. Cuando la evidencia observada de un MF relativo a una ubicación se ingresa en el modelo, este se puede usar para identificar y confirmar los MD más probables involucrados en el MF. Dado que el modelo indica el grado de susceptibilidad de las filas de álabes a los MD modelados, proporciona al personal de mantenimiento información sobre si reparar solo la (s) fila (s) de álabes averiadas o extender las tareas de reparación a otras filas no dañadas, pero susceptibles. Para las inspecciones preventivas, las indicaciones de daño de inspecciones pasadas, hipótesis o suposiciones del analista pueden insertarse en el modelo para evaluar los cambios en la probabilidad de otros MD, evaluando la contribución al fallo ante diferentes posibles escenarios.

La capacidad de manejar la susceptibilidad del daño en las ubicaciones de la turbina proporciona mejor información para decidir el alcance de las actividades de mantenimiento. Se prevé que este modelo puede proporcionar al personal de mantenimiento e inspección con referencias de dónde es necesario invertir mayor atención, recursos y tiempo, en dependencia de dónde la RB indica que el daño es más probable que ocurra, información de especial utilidad bajo programas de mantenimiento con calendarios ajustados. El modelo puede proporcionar resultados incluso cuando hay información desconocida o parcialmente conocida (por ejemplo, no se sabe con certeza si hay un MD presente). El conocimiento experto almacenado en la red es en sí mismo un valioso activo intangible, listo para ser analizado antes y/o durante el mantenimiento, actualizado y compartido si es pertinente.

4.7.2. Contribuciones para los métodos de cómputo de las TPC

El método de cálculo de las TPC expuesto en los pasos de la Sección 4.4.2 difiere de otros métodos en la literatura ya que se utiliza un enfoque de múltiples *leaks* para cada nodo, opción más propicia para la inclusión de todas las combinaciones de variables de ubicación. La opción de múltiples *leaks* por TPC es necesaria para la implementación del procedimiento de clasificación de susceptibilidad de las ubicaciones al daño, que contrasta con la convención general de que cada TPC posee un solo valor *leak*.

La matriz de *leaks* se combina luego con el modelo ENOR en pasos posteriores, lo que permite considerar la sinergia de los MD, diferenciándose del común uso de modelos ICI,

donde no existen interacciones entre los mecanismos causales. De esta manera, el método de cálculo de las TPC, en su conjunto, es novedoso y ofrece la posibilidad de generar grandes tablas a partir del juicio de expertos para un nodo con entradas de una combinación de padres binarios y de múltiples estados.

El método de cálculo TPC desarrollado logra una reducción en el número de valores que debe proporcionar el experto. El nodo con la TPC más grande que se modeló en este capítulo (CF_MD) tiene 288 combinaciones, producto de sus tres nodos padres binarios clasificados y dos nodos padres de múltiples estados no clasificados con 4 y 9 estados respectivamente (ver el trabajo de Díez [81] para el formalismo de variables graduadas). Para estas 288 combinaciones, el método necesita un máximo de solo 20 valores de un experto como entrada, siempre que todos los PIC de segundo orden sean provistos por el experto, aunque esta condición no es necesaria. Los 20 valores incluyen nueve números de susceptibilidad para las filas, cuatro para la parte/porción del álabe, un factor *leak* y seis valores PI (tres PII y tres PIC). Estos valores se obtienen con sólo nueve preguntas.

4.7.3. Extensibilidad del modelo

El enfoque seguido se puede aplicar a otros sectores industriales que utilizan turbinas, independientemente de la tecnología (nuclear, fósil), el fluido de trabajo (gas, vapor), el propósito (aviación, producción de energía, procesos industriales) y la cantidad de filas de álabes. En general, se puede aplicar a sistemas donde varios MD pueden coexistir e influir entre sí. Los MD se modelan como dependientes de las variables de ubicación que se pueden definir explotando las propiedades simétricas del sistema. La red resultante se puede estructurar para adaptarse a turbinas específicas de la industria con diferentes características, ya que los MD y sus influencias serán específicos de la industria en estrecha relación con la forma de operación. Además, los estados para los nodos de ubicación dependen de la discretización elegida que difieren de un sistema a otro. Estas diferencias deben tenerse en cuenta en el proceso de cuantificación descrito en la sección 4.4.2, donde las matrices resultantes pueden ser de diferente tamaño; sin embargo, el proceso sigue siendo el mismo.

4.8. Resumen y conclusiones parciales: modelo de RB para una turbina de vapor

Se ha desarrollado una herramienta de análisis basada en RB para la identificación de los MD a partir de la evidencia disponible en el mantenimiento de la turbina de vapor, favoreciendo la toma de decisiones de mantenimiento con nueva información que contempla las dependencias condicionales entre los MD y su relación con las partes susceptibles de la turbina. En el presente capítulo se ha expuesto la metodología general a seguir para su confección, ejemplificando con los MD más comunes en turbinas de centrales nucleares. De lo presentado en el capítulo se extraen las siguientes conclusiones:

1. Las RB ofrecen una solución adecuada para modelar las dependencias condicionales que existen entre los MD, y de estos con la ubicación de los álabes dentro de las turbinas de vapor, proporcionando una herramienta de identificación de los MD que contribuyen a los fallos, por lo que se considera probada la subhipótesis planteada en el Capítulo II.
2. El modelo basado en RB, además de ser una herramienta de identificación de los MD a partir de observaciones directas durante el mantenimiento, proporciona a los encargados de mantenimiento la posibilidad de ejecutar diferentes tipos de análisis para identificar ubicaciones susceptibles, análisis de sensibilidad con evidencia observada o supuesta antes y/o durante las actividades de mantenimiento.
3. El modelo posee una granularidad que permite descomponer los MF en sus MD, y asociar ubicaciones susceptibles, ofreciendo capacidades aumentadas para entender las causas de los fallos de los álabes, información útil para las subsecuentes actividades de mantenimiento.
4. El nuevo método de cuantificación de las TPC con base en criterio de experto, necesario para cumplir los requerimientos de modelación especificados en la sección 4.4.1, es novedoso debido al proceso de categorización de la susceptibilidad de las ubicaciones de la turbina a los MD, el cual necesita de un enfoque de múltiples *leaks* por TPC. Además, su combinación con el nuevo modelo ERNOR (cuyas potencialidades ya han sido expuestas en el Capítulo III), considera las influencias sinérgicas de los MD, por lo que, en su conjunto, es

versátil y ajustable a cualquier turbina, generando grandes TPC con relativamente pocos datos de entrada.

5. El modelo de RB ha sido validado para comprobar la coherencia entre sus resultados y los datos de entrada, concluyendo que se comporta de manera lógica ante los diferentes tipos de análisis y evidencias introducidas en diferentes nodos.
6. La presente metodología puede aplicarse a otros tipos de turbinas de diferentes tecnologías, industrias y tamaños.

Capítulo V: Evaluación de las dependencias dinámicas de los mecanismos de daño

En el capítulo anterior se describió un modelo de RB que funge como una herramienta versátil de análisis para complementar el proceso de identificación de los MD en las turbinas de vapor. Una limitación del modelo de RB, tal como está concebido, es que no contempla el tiempo, por lo que es un modelo estático, significando que no es posible observar la evolución temporal de los MD, solamente saber sus contribuciones relativas a partir de la evidencia puntual introducida. Aunque el modelo estático proporciona información útil para las etapas subsecuentes del mantenimiento, como ya se ha demostrado, éste no puede considerar explícitamente las acciones de mantenimiento que pueden ocurrir en cualquier momento de la vida del equipo.

También es conocido que modelos más tradicionales de APS como el AF, normalmente basan su máxima granularidad a un nivel de componentes, siendo estos los eventos básicos (EB). En los AF tradicionales a cada EB se le asigna un modelo de probabilidad de fallo, es decir, una FDP que depende de ciertos parámetros, con los cuales es posible calcular la probabilidad de fallo. La integral en el tiempo de la FDP es más usada para describir el incremento de la probabilidad de fallo, resultando en una FDA (ver sección 3.2). Entre las FDP más comunes se encuentra el modelo exponencial, que considera una tasa de fallos constante (de forma general, función de riesgo o *hazard function*). También se encuentra la Weibull, una de las más usadas debido a su versatilidad en las formas que toma cuando posee al menos dos parámetros (forma y escala), entre muchas otras, cada una de gran utilidad para describir el comportamiento de diferentes tipos de componentes.

Lo usual es asignar una FDP por cada EB de acuerdo con la estadística disponible y de esta forma calcular su FDA para determinar la probabilidad de fallo. Existen varias formas de aumentar la granularidad con la que se analiza un componente, o descomponer en partes más pequeñas lo que en algunos estudios conforma un EB. Una forma es dividiéndolo en subcomponentes físicamente delimitados o regiones, por ejemplo, una válvula es fácilmente separable en sus partes internas, o en el ejemplo del álabe, éste

se descompuso en cuatro partes o porciones. Otra forma es dividir el componente de interés en un conjunto de elementos que representan mecanismos de daño con interconexiones, en vez de subelementos físicos o regiones. El modelo estático del Capítulo IV es una combinación de ambas formas de aumentar la granularidad.

La segunda opción es aplicable, por ejemplo, a elementos estructurales que ejercen una función sin partes móviles. Este es el caso de un álabe de turbina, de porciones grandes de rotores, superficies que retienen un fluido como tuberías, vasijas como las de un reactor, paredes de hormigón, etc. Normalmente estas estructuras sufren un deterioro por diferentes MD que van degradando su capacidad de ejercer su función en las condiciones de operación para las que han sido diseñadas. Eventualmente es necesario reemplazarlas, si es posible, o repararlas de forma tal que los MD que actúan sean eliminados o mitigados para extender la vida útil. Lo anteriormente discutido permite razonar que la asignación de una sola FDP para componentes afectados por varios MD que pueden estar presentes o ausentes en ciertos momentos no puede captar correctamente las complejas variaciones en la probabilidad de fallo.

En consecuencia, en este capítulo el componente se divide en sus MD, agregando la variable temporal. Una forma de hacerlo es simplemente asignando una FDP a cada MD, los cuales serían los nuevos EB, y acoplarlos mediante una tradicional compuerta OR. Así, se obtendría una curva de probabilidad de fallo asumiendo que todos los MD provocan el fallo de forma independiente, de nuevo, la restricción ICI. Sin embargo, como se ha explicado con anterioridad en esta tesis, el concepto de independencia es una suposición fuerte y limitativa para problemas complejos de ingeniería. Ya se ha explicado que existen MD que, en caso de estar presentes, aceleran el daño que provocan otros MD a los cuales el componente es susceptible. Intuitivamente, la no consideración de dichas dependencias implica una subestimación de la probabilidad de fallo en componentes susceptibles a diversos MD.

Las actividades de reparación de los componentes o estructuras en el mundo real, cuando no son reemplazados completamente o se considera un mantenimiento perfecto, se enfocan en frenar o restablecer el daño provocado por ciertos MD. Suponga que un daño superficial es eliminado y tome como ejemplo una pared que es pintada para

restablecer su protección ante la erosión o la humedad. Esta acción no es efectiva contra el daño interno que ya pudo haberse provocado por la humedad. En tal situación, la vida útil de la pared se ha extendido en cierta cantidad de tiempo porque se ha restablecido la protección externa o superficial, que ya estaba debilitada (la pintura), pero el daño interno no se ha eliminado, y en el mejor de los casos, se ha frenado el deterioro interno por la humedad (p. ej., la posible corrosión de las vigas de metal de refuerzo) que eventualmente seguirá degradando la pared. Nuevamente, considerar un modelo para describir la probabilidad de fallo de la pared como un EB con una sola FDP asignada es una forma simplificada de hacer el cálculo, tal vez insertando un factor que implique el grado de imperfección del mantenimiento hecho. Sin embargo, la curva de probabilidad de fallo obtenida después de este momento posee limitaciones porque no contempla la posibilidad de que la corrosión de las vigas se haya frenado, o una aceleración de dicho daño una vez que la pintura nuevamente comience a deteriorarse y la humedad comience a actuar nuevamente.

Cuando se introduce una variable temporal, los cambios mencionados en la probabilidad de fallo de los componentes afectados por diversos MD que interactúan entre ellos, no se producen súbitamente dado que un mecanismo se torna presente o ausente, como sí ocurre en los modelos estáticos. Contrariamente, la evolución de un MD hasta provocar el fallo es un proceso que toma tiempo, al igual que la influencia que un MD puede ejercer sobre otro dependiente. Se trata entonces, de modelar cambios complejos en la función de riesgo del componente. Estos cambios en la función de riesgo, cuando ciertos MD están presentes y otros se tornan ausentes por acciones de mantenimiento generarán una FDA compleja para el componente, imposible de modelar si se toma el componente como un EB sin considerar sus MD.

De las cuestiones analizadas, se hipotetiza que la consideración de independencia entre los MD que afectan la confiabilidad de un componente se traduce en una subestimación de la probabilidad de fallo calculada, en comparación con la consideración de mecanismos que pueden acelerar el desarrollo de otros MD dependientes.

Por tanto, en el presente capítulo se propone un modelo en el cual se tienen en cuenta explícitamente, y de forma dinámica, los MD y sus dependencias que contribuyen al fallo

de los componentes. Con el incremento en la granularidad del modelo se considera el mantenimiento de forma diferenciada para cada MD, con lo cual se asume intrínsecamente el mantenimiento imperfecto debido a la prevalencia de los demás MD que no han sido afectados por la actividad de mantenimiento. Dicho de otra forma, se trata de extender las capacidades del modelo presentado en el Capítulo IV, incorporando la variable temporal y las acciones de mantenimiento imperfecto de forma explícita.

Para lograr el objetivo se utiliza el modelo ERNOR en su forma dinámica desarrollado en el Capítulo III. Ahora las causas del Capítulo III cobran el sentido de MD, y la salida del ERNOR es la probabilidad de influencia conjunta dinámica que todos estos MD ejercen sobre otro MD considerado como dependiente.

A modo de cronología, el modelo en un inicio se intentó realizar considerando RB dinámicas (RBD) y posteriormente RB con nodos tipo función, pero la complejidad de las dependencias entre los MD en función del tiempo, sus FDA y la cantidad requerida de pasos temporales hizo infructíferos dichos esfuerzos con los programas computacionales de RB disponibles para la investigación. Aunado a lo anterior, la introducción de mantenimientos diferenciados para cada MD dinámico terminó poniendo punto final al intento de uso de las RB en la confección del modelo. Posteriormente, el modelo finalmente se implementa en una hoja de cálculo, usando Excel, en el cual fue necesario implementar algoritmos de cálculo en VBA (Visual Basic para Aplicaciones).

5.1. Sistemas y componentes sujetos a mantenimiento

Esencialmente, mediante la consideración de los MD que afectan a un componente y de mantenimientos que afectan directamente a unos MD y a otros no, se está hablando de un componente con una función de riesgo compleja. Dicha función de riesgo es afectada por la FDP independiente de cada MD, pero como estos pueden ser dependientes, e incluso tornarse ausentes por el efecto de una acción de mantenimiento, es prácticamente imposible desarrollar una expresión analítica de la función de riesgo que regiría el comportamiento global de la FDA resultante para el componente modelado. Es pertinente recordar que la tasa de incremento del daño dependiente del tiempo, o sea, la función de riesgo se define, entre otras formas equivalentes como:

$$h(t) = \frac{f(t)}{R(t)} \quad (44)$$

Donde $f(t)$ es la FDP y $R(t)$ es la confiabilidad, complemento de la probabilidad de fallo. A continuación, se realiza una revisión literaria de métodos que han sido propuestos para considerar componentes y sistemas reparables con funciones de riesgo dependientes del tiempo y de otros factores que producen cambios en la forma en que crece la probabilidad de fallo.

El modelo de función de riesgo proporcional [104], [105] considera que existe una función de riesgo base $\lambda_0(t)$ para un componente que se incrementa en el tiempo, afectada por una función $\psi(\beta_i x_i)$ de factores ambientales x_i y coeficientes β_i a los cuales se expone el componente y como resultado, acortan su vida útil. La expresión (45) demuestra el concepto.

$$\lambda(t) = \psi(\beta_i x_i) * \lambda_0(t) \quad (45)$$

La función de riesgo base puede ser determinada estadísticamente a partir de los fallos que se producen en un ambiente de referencia. La función $\psi(\beta_i x_i)$ puede ser lineal o exponencial, cuyos coeficientes se determinan mediante un análisis de regresión a partir de los datos de fallo del componente. Como ha sido señalado en [106, p. 79], el efecto neto de los factores ambientales sobre la función de riesgo es en esencia, aditiva.

Una forma de considerar estocásticamente el cambio de una función de riesgo es mediante la inserción de funciones estocásticas [107]. Suponga que S_n son épocas discretas de un intervalo de tiempo ($n \geq 1$), y en cada una puede ocurrir un choque D_n que genera estrés en el componente. También asuma que existe una función de atenuación $h(t)$ que representa la capacidad del componente de recuperarse del choque que provoca estrés. Entonces la expresión general para la función de riesgo es (46).

$$\lambda(t) = \sum_{n=1}^{\infty} D_n * h(t - S_n) \quad (46)$$

Para sistemas sujetos a reparación, trabajos tempranos como el de Nakagawa [108], asumen que la función de riesgo $\lambda(t)$ luego del mantenimiento de un componente es reducida en una fracción de la que tenía antes del mantenimiento $\lambda(T)$. La ecuación general para el próximo ciclo de operación es $\lambda(t) = g(\theta_i) * \lambda(T + t)$. La función $g(\theta_i)$ describe la cantidad en que se reduce de la tasa en un mantenimiento y depende de varios parámetros θ_i . Como ejemplo asuma el capital invertido en mantenimiento, suponiendo que, si este es igual al costo inicial del sistema, se llega a un mantenimiento perfecto. Otras funciones reductoras son aplicables a diferentes contextos más realistas. Note que la estructura es en esencia la misma que la del modelo de función de riesgo proporcional, expresión (45), sin embargo, el enfoque proporcional considera variaciones de la tasa por factores ambientales externos y el de Nakagawa considera los efectos de un mantenimiento.

Brown y Parscham [109] consideran que el mantenimiento puede ser perfecto con probabilidad p , por lo que la condición de tan malo como antes es $1 - p$. Bajo esta asunción demuestran que para cualquier FDP, su función de riesgo es proporcional a p , corroborando el modelo de Nakagawa [108].

Por otra parte, Malik [110] propone un modelo de mantenimiento imperfecto en el cual la función de riesgo es un polinomio dependiente del tiempo, aunque puede extrapolarse a otras funciones. Su aporte al mantenimiento imperfecto es considerar un factor de mejoramiento para los componentes cuyo efecto es modificar el tiempo en el que se evalúa la función de confiabilidad. Si T es el momento en el cual se efectúa el mantenimiento y $\beta \in [1; \infty)$, entonces luego del mantenimiento, la probabilidad de fallo se evalúa en T/β , es decir, $F(T/\beta)$. Entonces $\beta = 1$ significa que el mantenimiento no mejoró la confiabilidad del componente, mientras que un número grande implica que el componente disminuye su probabilidad de fallo y su función de riesgo simultáneamente. Se asume que el especialista en mantenimiento es capaz de dar un estimado de β .

Aunque Malik [110] no lo hace explícitamente, años después Kijima [111] formaliza el concepto de “edad virtual”, donde se modifica el tiempo en el que se evalúa el sistema. Aquí se expresa que un sistema posee una edad virtual V_{n-1} justo luego de aplicar el mantenimiento $(n-1)$ -ésimo. Luego, la nueva edad virtual sigue aumentando por calendario hasta llegar al n -ésimo mantenimiento, donde existen dos modelos para calcular la edad virtual en ese momento. El primer modelo es $V_n = V_{n-1} + A_n t$ y el segundo es $V_n = A_n(V_{n-1} + t)$. En el primero se considera que el nuevo mantenimiento afecta la edad virtual del último período de operación en un factor $A_n \in [0; 1]$, sin afectar la edad virtual hasta el mantenimiento previo, por lo que el sistema sólo se restaura hasta V_{n-1} como máximo, cuando $A_n = 0$. En el segundo, el factor A_n afecta, además, la edad virtual del mantenimiento anterior, pudiendo llegar a un mantenimiento perfecto para $A_n = 0$. En ambos casos, para $A_n = 1$ se asume que el sistema es tan viejo como antes.

Un modelo simple describe lo que le ocurre a la función de riesgo cuando es reparado [112], [113, p. 273]. La función de riesgo es dividida en dos, cuya expresión general es $\lambda(t) = q\lambda(0) + (1 - q)\lambda^*(t)$. La primera componente $\lambda(0)$, representa la tasa cuando el sistema es nuevo y la segunda, $\lambda^*(t)$, representa la tasa del sistema envejecido. Ambas componentes están ponderadas por el factor de peso q , que toma valores entre cero y uno y representa la calidad del mantenimiento. Para $q = 1$ se asume un mantenimiento perfecto y el sistema se comporta como nuevo. Para $q = 0$ la condición es mantenimiento mínimo, es decir, el sistema funciona, pero es tan viejo como antes.

5.2. Teoría del modelo para mecanismos de daño dependientes y dinámicos

Como ya se ha explicado anteriormente, los mecanismos de daño de un elemento pueden interactuar entre sí. La presencia de unos MD puede incrementar la probabilidad de ocurrencia de otros mecanismos. A los primeros se les llamará mecanismos de daño potenciadores y a los segundos, dependientes, conceptos que se ajustan mejor a este capítulo que simplemente nodos padres e hijos, en especial porque ya no se usan RB, aunque las explicaciones gráficas siguen un patrón de nodos y arcos. En el modelo de RB estática del Capítulo IV, este incremento en la probabilidad es independiente del tiempo y simplemente ocurre un aumento en la probabilidad cuando se activa un MD padre. Sin embargo, para un modelo dinámico, esta influencia no ocurre de la misma

manera ya que la probabilidad de ocurrencia de los potenciadores va incrementándose paulatinamente y su efecto en el mecanismo dependiente ocurre de forma continua hasta que el componente de interés es mantenido y el efecto del MD potenciador desaparece. En otras palabras, un MD potenciador modifica la tasa de incremento del daño (función de riesgo) que un mecanismo dependiente puede ejercer sobre el componente donde coexisten.

En esta sección se explican en profundidad las particularidades de un componente modelado dinámicamente en donde coexisten mecanismos potenciadores y dependientes, dando lugar a una estimación de la probabilidad de fallo que es menos conservadora que considerar todos los MD involucrados como independientes. También se estudia el efecto de ejercer mantenimiento en el componente. En el caso general, el mantenimiento puede eliminar ciertos mecanismos y otros no, por lo que las curvas de confiabilidad pueden adquirir formas complejas. Este comportamiento es también analizado.

5.2.1. Conceptos básicos

Suponga que en un componente coexisten n mecanismos de daño que pueden o no generar directamente el fallo del componente. Para ejemplificar, y sin perder generalidad, suponga que existen exactamente seis mecanismos de daño en un componente de interés. A los primeros cinco MD les corresponde una FDA que se denota $F_{x_i}(t)$, donde $i \in [1, \dots, n]$ es un contador que identifica cada mecanismo. Independientemente de si estos primeros cinco pueden o no provocar el fallo del componente, se sabe que existe un sexto mecanismo Y_l con un daño acumulado provocado al componente denotado como $F_{Y_l}(t)$. También se sabe que la función de riesgo (44) de este daño acumulado por Y_l , denotado como $h_{Y_l}(t)$, depende los primeros cinco MD mencionados, es decir, que $h_{Y_l}(t)$ depende de $F_{x_i}(t)$.

Los mecanismos potenciadores de Y_l son los x_i , con funciones $F_{x_i}(t)$. Sin embargo, debido a explicaciones que se llevan a cabo más adelante en el transcurso de esta sección, resulta conveniente declarar una función acumulada intermedia para cada uno,

la cual se llama función potenciadora (FP), y se denota como $F_{x_i}^p$. Por el momento se asume que $F_{x_i}(t) = F_{x_i}^p$.

En la Figura 13 se presenta un esquema de conexión entre los mecanismos que coexisten en un componente.

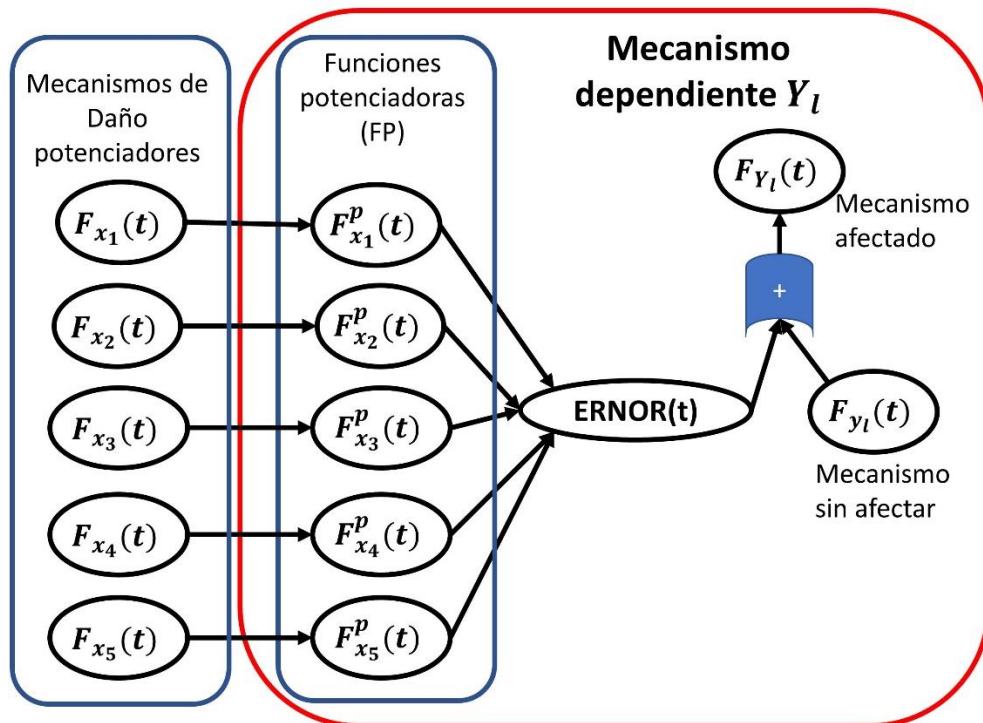


Figura 13: Esquema de conexiones de los MD considerando dependencias.

Como se observa, el daño acumulado por el mecanismo dependiente Y_l (nodo tope) se descompone en dos partes: primero en su distribución antes de ser afectado por los MD potenciadores, esta es $F_{y_l}(t)$; segundo, en un grupo de MD potenciadores que ejercen su influencia dinámica a través de sus FP que se combinan según el modelo ERNOR dinámico. Ambas partes se combinan en última instancia mediante una compuerta lógica OR. La distribución de Y_l antes de ser afectada por los MD potenciadores, es decir, $F_{y_l}(t)$, se comporta de forma análoga al *leak* de los modelos causales estáticos. Teniendo en cuenta esto, $F_{y_l}(t)$ es la probabilidad acumulada del mecanismo Y_l cuando no existe ningún otro mecanismo considerado en el modelo que pueda afectar su comportamiento.

5.2.2. Condiciones del modelo

El modelo presentado en la Figura 13 por sí solo no es capaz de modificar a Y_l a través de afectaciones a su función de riesgo $h_{Y_l}(t)$ con mantenimientos, como se ha explicado anteriormente. Para lograr esto, se introducen dos condiciones relacionadas con el efecto del mantenimiento sobre los diferentes MD. A continuación, ambas se explican en detalle.

Condición 1: La eliminación súbita del mecanismo dependiente Y_l del componente por alguna actividad de mantenimiento implica que su *leak*, sus MD potenciadores y sus FP se restablecen a cero, dando lugar a un nuevo ciclo de desarrollo del mecanismo Y_l en donde las influencias de los MD potenciadores comienzan desde cero. Al mantenimiento que se ejerce sobre el mecanismo dependiente Y_l en el momento T se le denota $M_{Y_l}(t = T)$.

Debido a que la implementación del modelo en la hoja de cálculo es discreta en el tiempo, la unidad denominada st es el salto temporal para el cual se calculan los valores de probabilidad. Cada st posee una duración de acuerdo con las necesidades de la modelación. Para propósitos de simplicidad, se considera que el mantenimiento tiene una duración de $1ts$.

Teniendo en cuenta lo anterior, se tiene que el *leak*, $F_{Y_l}(t = T + 1ts) = 0$, y simultáneamente la influencia de todos los mecanismos potenciadores y sus respectivas FP se reinician, esto es $F_{x_i}(t = T + 1ts) = F_x^p(t = T + 1ts) = 0$. Lo anterior da lugar a un nuevo ciclo de operación que para el mecanismo dependiente en cuestión comienza en $F_{Y_l}(t = T + 1ts) = 0$. Es decir, que cuando se hace mantenimiento y se elimina el mecanismo Y_l , se entiende que el daño provocado por este mecanismo se elimina totalmente del componente y se eliminan también los MD potenciadores con sus influencias hacia el mecanismo Y_l . Es un modelo de mantenimiento perfecto para Y_l .

La condición 1 es fácilmente modelada con una estructura igual a la presentada en la Figura 13. En este sentido la condición 1 establece que la aplicación de $M_{Y_l}(t = T)$ afecta a todos los mecanismos involucrados y se logra mediante una señal que restablezca la probabilidad a cero simultáneamente en los MD potenciadores, sus FP y el MD

dependiente. La Figura 14 ilustra el concepto del tipo del mantenimiento en cuestión. La flecha roja continua representa la intención del mantenimiento, eliminar el mecanismo Y_l . Las flechas rojas discontinuas apuntan a los elementos del modelo que realmente deben ser afectados para lograr la condición 1, con la descripción dentro de los globos de texto.

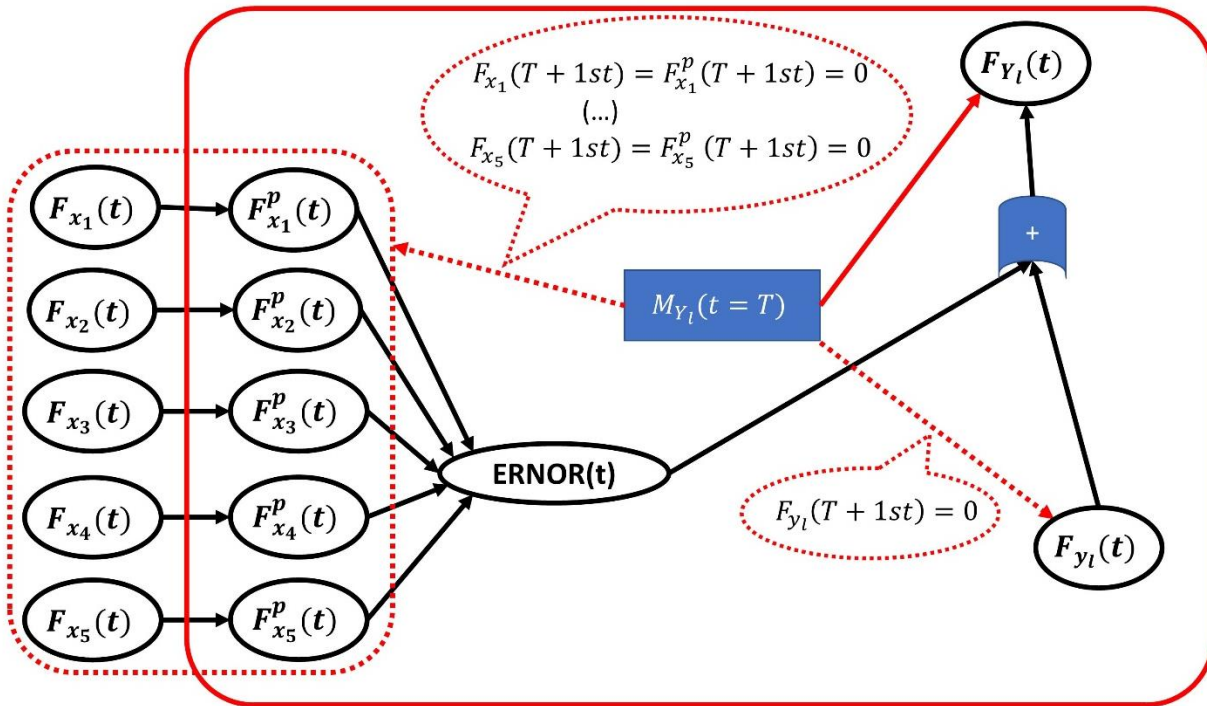


Figura 14: Señal de mantenimiento $M_{Y_l}(t = T)$.

El efecto en las curvas de confiabilidad se muestra en la Figura 15. Se han utilizado los mismos valores que en la Tabla 4 para las probabilidades de influencia (PI) de los potenciadores en el modelo ERNOR, y que en la Tabla 5 para sus FDA, que son distribuciones de Weibull. La Weibull para F_{y_l} es $W(escala = 3; forma = 20)$. Por simplicidad, $1ts = 1$ es decir, una unidad temporal, sin prestar atención a la dimensión del tiempo (hora, mes, año...).

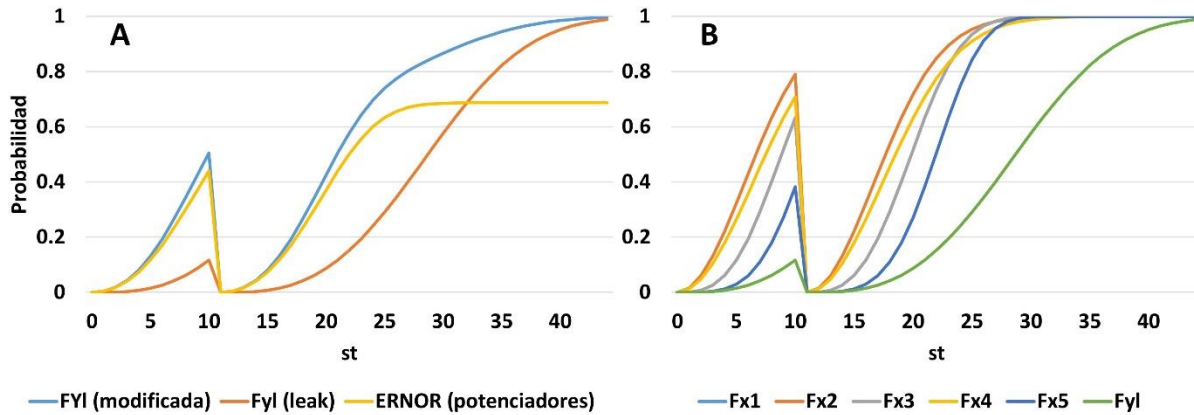


Figura 15: Mantenimiento $M_{Y_l}(t = 10)$

En la Figura 15A se muestran las tres curvas principales, la probabilidad total del mecanismo Y_l modificada por sus potenciadores, esta es F_{Y_l} , su *leak* F_{y_l} y la curva que describe la influencia conjunta de los MD potenciadores x_i a través del modelo ERNOR dinámico. En la Figura 15B se muestran las curvas F_{x_i} de los MD y la F_{y_l} (el *leak*). Se observa que $M_{Y_l}(t = 10)$ produce curvas de confiabilidad que se reducen a cero en $ts = 11$.

Condición 2: La eliminación de todos los mecanismos potenciadores, o de un subconjunto de los n mecanismos, es decir, $F_{x_i \in n}(0) = 0$, no puede disminuir el daño que hasta ese momento el mecanismo dependiente Y_l ha provocado en el componente. Al mantenimiento de algún potenciador x_i que afecta a Y_l en el momento T se le denota $M_{Y_l-x_i}(t = T)$. Los mecanismos x_i son sólo potenciadores del crecimiento de Y_l , modificadores de su función de riesgo $h_{Y_l}(t)$ y, por lo tanto, la eliminación súbita de algún x_i provoca un cambio repentino en dicha función de riesgo, no en el valor puntual de la probabilidad acumulada del mecanismo dependiente $F_{Y_l}(t)$.

La condición 2 es más compleja de modelar debido a que si se restablecen los MD potenciadores y con ellos sus respectivas FP, es decir, $F_{x_i}(T + 1ts) = F_{x_i}^p(T + 1ts) = 0$ (recuerde que el mantenimiento dura un paso temporal), da por resultado un decrecimiento en la probabilidad $F_{Y_l}(t)$ acorde con la compuerta tope OR. Este no es el comportamiento que se requiere porque implicaría que los MD potenciadores, al

eliminarse por mantenimiento, disminuyen el daño ya creado por el mecanismo afectado o potenciado. Dicho de otra forma, la condición 2 establece que si solamente se eliminan los potenciadores, y la parte independiente del mecanismo afectado $F_{Y_i}(t)$ sigue creciendo, entonces el resultado $F_{Y_i}(t)$ no debe sufrir una disminución en la probabilidad, sólo un cambio de pendiente consecuente con un cambio en la influencia que los potenciadores eliminados ejercían antes del mantenimiento, y que ya no ejercen. Recuerde el ejemplo de la pintura de la pared: si se restablece dicha capa protectora, se esperaría que el daño interno se retrasara, pero no desaparece.

Para lograr el efecto deseado de la condición 2 se recurre a crear un código con dicho propósito. El objetivo del código es manipular las funciones potenciadoras $F_{x_i}^p(t)$ a partir de $t = T$ cuando llega una señal de mantenimiento que sólo afecta a los potenciadores, de forma tal que la probabilidad acumulada de las FP en cuestión se detenga exactamente en el momento que comienza el mantenimiento y, una vez ejecutado éste, continúe creciendo con una función de riesgo h_{x_i} renovada. Dicha manipulación sólo se aplica a $F_{x_i}^p(t)$ y no a $F_{x_i}(t)$, es decir que cuando ocurre $M_{Y_i-x_i}(t = T)$ se tiene que $F_{x_i}(T + 1ts) = 0 \neq F_{x_i}^p(T + 1ts)$. La curva de la FP afectada es

$$F_{x_i}^p(t) = \begin{cases} F_{x_i}(t) & \forall t \leq T \\ 1 - [1 - F_{x_i}(t = T)] * [1 - F_{x_i}(t' = t - T)] & \forall t > T \end{cases} \quad (47)$$

La expresión (47) implica dos períodos. El primero va de 0 a T , donde la curva de la FP es igual a la del MD potenciador asociado. Luego ocurre el mantenimiento al potenciador en T y su FDA cae a cero inmediatamente luego de esto, sin embargo, la curva de su FP no se reduce debido a que queda evaluada en T y a partir de allí reanuda su crecimiento cuando el potenciador correspondiente comienza a crecer nuevamente, por lo que t' implica el nuevo período para el MD potenciador.

La Figura 16 ilustra el concepto de mantenimiento al MD potenciador x_5 y la transformación que ocurre con su FP. La flecha roja continua representa la intención del mantenimiento, eliminar el mecanismo potenciador x_5 , cuya distribución acumulada

retorna a cero. La flecha roja discontinua apunta a la FP correspondiente, que debe ser modificada según la expresión (47) para lograr la condición 2.

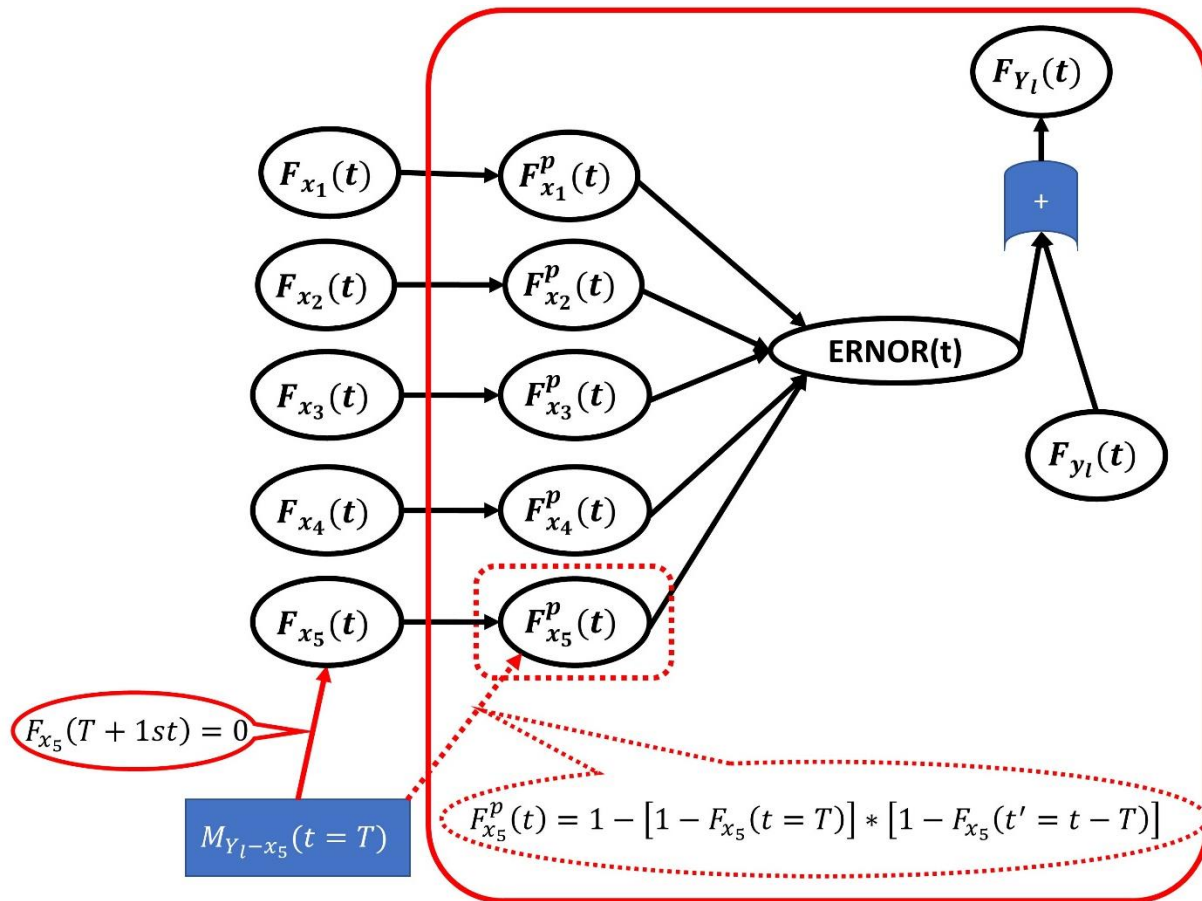


Figura 16: Señal de mantenimiento $M_{Y_l-x_5}(t = T)$.

La Figura 17 muestra el efecto de eliminar los cinco potenciadores simultáneamente en $T = 10$. En la Figura 17B se muestra el efecto sobre los acumulados de los MD potenciadores, esencialmente se eliminan del componente. Esto provoca un efecto en las funciones potenciadoras como se puede ver en la curva ERNOR de la Figura 17A. El resultado es que el daño acumulado $F_{Y_l}(t)$ sufre un cambio en su función de riesgo $h_{Y_l}(t)$ en consecuencia con la influencia que los potenciadores ejercían hasta antes del mantenimiento, pero que ya no existe luego de éste. Los datos usados para la Figura 17 son iguales que para la Figura 15.




Figura 17: Mantenimiento $M_{Y_l-x_5}(t = 10)$

5.3. Estudio de casos

En esta sección se muestran varios casos que ayudan a entender las influencias de los mecanismos potenciadores sobre uno dependiente. Como en la Figura 13, cinco mecanismos potenciadores x_i que pueden influenciar el comportamiento del mecanismo dependiente Y_l son utilizados.

5.3.1. Variación del momento de mantenimiento de los potenciadores

En la Figura 18 se muestra el resultado del mecanismo afectado por los potenciadores cuando estos se eliminan, en diferentes momentos y de forma simultánea, por acción de un mantenimiento. Cuando no existe influencia de los mecanismos potenciadores (serie: sin influencia), ocurre la igualdad $F_{Y_l}(t) = F_{y_l}(t)$, es decir, que sólo existe la parte *leak*. La serie “toda influencia” corresponde a la compuerta tope OR, es decir, $F_{Y_l}(t)$, a la cual tributan la compuerta ERNOR dinámica y el *leak* $F_{y_l}(t)$, cuando todos los mecanismos potenciadores comienzan a crecer desde cero, ejerciendo su influencia a medida que su presencia es más fuerte. Entre estos dos casos extremos se encuentran los casos en que los potenciadores son desactivados simultáneamente en diferentes momentos, para los $st = 3$, $st = 10$ y $st = 14$.




Figura 18: Influencia sobre $F_{Y_l}(t)$ de $M_{Y_l-x_{1,2,3,4,5}}(t)$ en diferentes momentos.

Note que la curva para el mantenimiento en $st = 3$ retrasa el crecimiento del mecanismo de daño Y_l respecto a cuando no existe mantenimiento y toda la influencia está presente, este comportamiento persiste durante toda la vida útil del componente. Sin embargo, es de notar que el mantenimiento en $st = 14$ logra un efecto retardante del daño en las últimas etapas de la vida del componente y que incluso logra una probabilidad de fallo menor luego del punto 18 que la curva con mantenimiento en $st = 3$. En este caso debe tenerse en cuenta que, a pesar de lo señalado, ya la vida remanente del componente es poca, su probabilidad de fallo es elevada, y el efecto provocado es relativamente insignificante. Se concluye entonces que, realizar mantenimientos a los MD potenciadores con el componente envejecido, no provoca un efecto significativo en el alargamiento de la vida útil del mismo, porque el mecanismo dependiente ya ha logrado deteriorarlo significativamente. Entre más tarde se haga mantenimiento a los potenciadores, menor es el efecto sobre el mecanismo dependiente. Por último, el mantenimiento realizado en $st = 10$ tiene mejores resultados que el realizado en $st = 14$ y se puede afirmar que esta estrategia ofrece mejor rendimiento para las etapas envejecidas del componente ($st > 14$) que el caso de $st = 3$.

Es obvio que una probabilidad de fallo de 0.4 es exagerada, sin embargo, el ejemplo de arriba es puramente ilustrativo y los valores fueron escogidos de esta manera para cubrir todo el rango de probabilidades en un ejemplo simple y que el efecto de los cambios fuera visualmente perceptible.

5.3.2. *Mantenimiento de subconjuntos de potenciadores*

A diferencia del caso anterior, donde para diferentes momentos se daba mantenimiento a todos los potenciadores simultáneamente, en la Figura 19 se muestran las curvas $F_{Y_l}(t)$ cuando, en $ts = 10$, la cantidad de MD potenciadores que son eliminados por mantenimiento, varía. En consecuencia con el modelo ERNOR, es de notar que entre mayor cantidad de MD potenciadores se eliminan simultáneamente, mayor es el impacto en los valores de $F_{Y_l}(t)$, retrasando su crecimiento en el tiempo. Note que los resultados son coherentes con los de la Figura 10 de la sección 4.5, donde se demostraba el tercer axioma de Jones *et al.* [103]. En este caso, se están eliminando cada vez mayor cantidad de potenciadores, por lo que la influencia sobre el mecanismo dependiente es cada vez mayor, alargando la vida útil del componente.




Figura 19: Influencia sobre $F_{Y_l}(t)$ del mantenimiento en subconjuntos de potenciadores.

5.3.3. Variación de parámetros en el leak

En la Figura 20 se muestra un análisis de sensibilidad del impacto de la forma de la distribución de $F_{y_l}(t)$ cuando existe $M_{Y_l-x_{1,2,3,4,5}}(st = 10)$. En la Figura 20-A se varía el parámetro de escala de $F_{y_l}(t)$ desde $\eta = 10$ hasta $\eta = 30$. A valores mayores de eta, la curva *leak* tiende a aplanarse y a correrse a la derecha, por lo que esto disminuye su velocidad de crecimiento, es decir, su función de riesgo $h_{y_l}(t)$ es menor al principio del período. La Figura 20A demuestra que entre mayor sea el valor de eta, la curva *leak* “pierde fuerza” ante la influencia de los potenciadores, por lo que cuando se realiza un mantenimiento a los potenciadores, el cambio en la función de riesgo del mecanismo dependiente $h_{y_l}(t)$ sufre un cambio mayor comparado con el momento antes del mantenimiento. Lo contrario se puede afirmar para valores de eta más pequeños, donde el *leak* “toma fuerza” respecto a las influencias de los potenciadores y las pendientes antes y después del mantenimiento son similares.




Figura 20: Sensibilidad del *leak* $F_{y_l}(t)$ para diferentes valores del factor de escala y forma.

Respecto a la variación del factor de forma, en la Figura 20B éste se varía desde $\beta = 0.5$ hasta $\beta = 6$ en la función *leak*. El impacto en $F_{y_l}(t)$ es que cambia el momento en el que ocurre una mayor densidad de puntos en su FDP, por lo que, a valores pequeños de beta, se produce un crecimiento abrupto a etapas tempranas y a valores mayores, el crecimiento se produce de forma más suave y requiere más tiempo. Aquí la influencia de los potenciadores es más fuerte para valores mayores de beta debido a que el

crecimiento del *leak* al inicio es pequeño, es decir, $F_{Y_i}(t)$ posee valores pequeños al inicio y por ende su contribución a $F_{Y_i}(t)$ es menos significativa. En cambio, para valores de beta pequeños, el *leak* crece mucho en poco tiempo, por lo que los potenciadores dejan de influir rápidamente debido a que el daño al componente se produce en etapas tempranas sólo por el *leak*.

5.4. Ejemplo del modelo para varios potenciadores y mecanismos dependientes

En la Figura 21 se muestra un concepto generalizado del modelo para considerar MD dependientes y dinámicos. Existe un componente que contiene seis mecanismos de daño. Cinco de ellos pueden provocar el fallo directamente, estos son $x_1, x_2, x_4, x_5, Y_1, Y_2$ y se reconocen porque están directamente conectados a la compuerta tope tipo OR. Desde el punto de vista de la modelación, el mecanismo x_3 no se considera que puede hacer fallar el componente, sin embargo, se considera que su presencia puede influir en el comportamiento de los demás MD como un potenciador. Una razón para que el analista pudiera decidir no conectar a x_3 directamente al fallo del componente es que el tiempo en que provoca el fallo por sí solo, es mucho mayor que el tiempo de estudio, o que los tiempos en que los demás mecanismos sí provocan fallos, por lo que es una forma de simplificar modelos complejos.

Los mecanismos x_1, x_2, x_3, x_4 son potenciadores del mecanismo Y_1 , mientras que x_4, x_5, Y_1 son potenciadores de Y_2 . Note que las estructuras dentro de los recuadros rojos de la Figura 21, con las condiciones 1 y 2, pueden encapsularse en un nuevo tipo de compuerta lógica para un AF, llamándole, por ejemplo, “compuerta de eventos potenciadores”, siendo sus contribuyentes los eventos que quedan fuera y la señal de mantenimiento correspondiente. Además, cada salida de la nueva compuerta puede tributar directamente a una compuerta lógica convencional del AF, o a otra compuerta de eventos potenciadores. La nueva compuerta debe contener los datos de las PI, las cuales se procesan internamente con el ERNOR dinámico para obtener las PI de órdenes mayores a tres, así como el tipo de FDP del *leak*.




Figura 21: Estructura general con varios MD potenciadores y dependientes.

5.5. Aplicación a un componente

En esta sección se presenta el modelo dinámico para un componente que contiene los mismos MD que el modelo presentado en el Capítulo IV.

En la Figura 22 aparecen las interacciones de los mecanismos considerados en el modelo estático. El modelo calcula la probabilidad de fallo de un álabes debido a la capacidad que tengan sus mecanismos de daño de producir el fallo. Cada MD que puede producir directamente el fallo está acoplado a la compuerta OR tope. Estos son SCC, CF, fatiga, picaduras e impacto por goteo. Se considera que la fricción no puede producir un fallo directamente, sin embargo, influye en el fallo del álabes a través de las conexiones con los mecanismos SCC y CF.

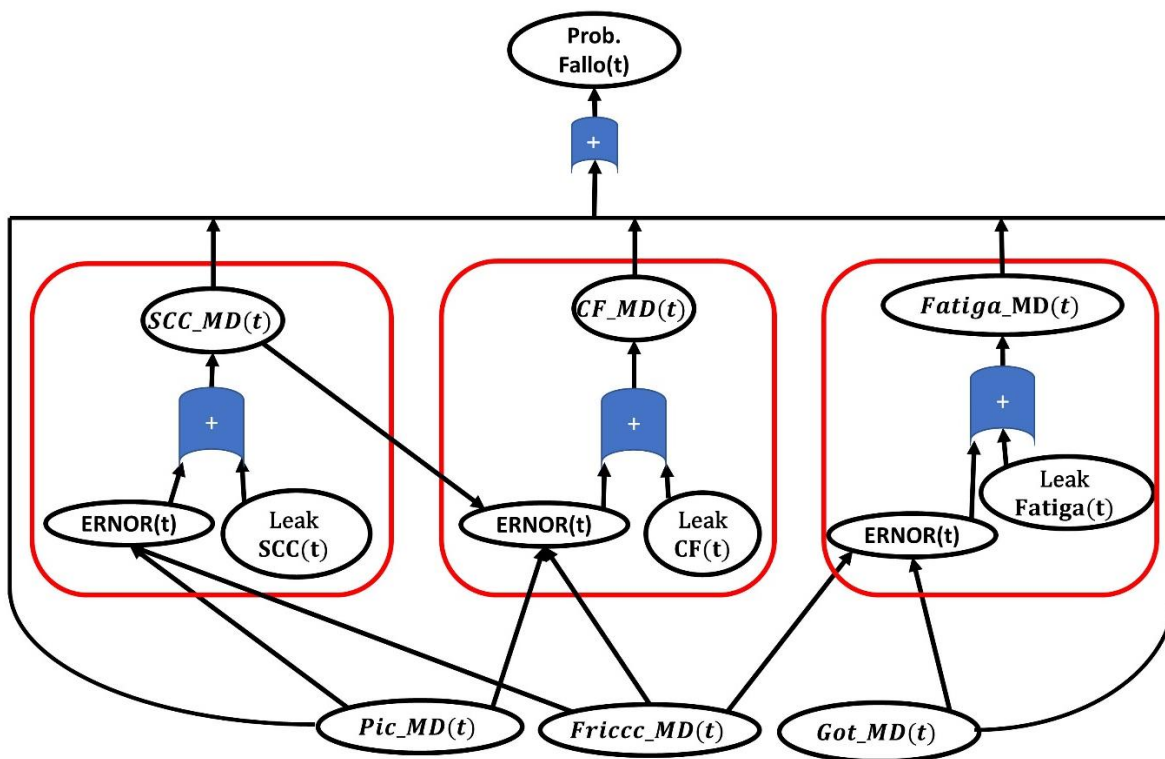


Figura 22: Modelo general para el álabe

Los mecanismos potenciadores están acoplados a otros mecanismos. Tienen el efecto de modificar la velocidad de crecimiento del mecanismo afectado. Si un mecanismo potenciador es eliminado, el efecto sobre el mecanismo afectado desaparece hasta que nuevamente el potenciador incrementa su probabilidad. En este caso, son potenciadores los mecanismos *Pic_MD*, *Got_MD*, *Fricc_MD* y *SCC_MD*. De estos, *SCC_MD* es también un mecanismo dependiente.

La Figura 22 muestra solamente la parte gráfica de conexiones, la parte no gráfica son las condiciones 1 y 2 que se explicaron en la sección 5.2.2 y que se implementaron en VBA. Para este modelo en específico, el mantenimiento adopta un enfoque de capas. El enfoque de capas determina cuáles son los mecanismos afectados con cada acción de mantenimiento, el cual se explica a continuación.

De acuerdo con el modelo propuesto y sus dos condiciones, es posible siempre eliminar algún subconjunto de mecanismos potenciadores mediante una acción de mantenimiento. Por ejemplo, en la Figura 19 se eliminan subconjuntos de potenciadores,

lo que provoca diferentes evoluciones del mecanismo afectado Y_i . Sin embargo, un componente real, o actividades de mantenimiento con ciertas limitaciones tecnológicas reales, pueden no aceptar la eliminación estricta de un MD potenciador, dejando a los demás intactos.

Por ejemplo, en un componente metálico en operación, sujeto a un ambiente hostil, como es el álabe de una turbina, existen mecanismos nucleadores del daño. Estos mecanismos pueden ser picaduras, erosión por goteo y el desgaste por fricción, los cuales actúan a un nivel superficial y elevan la probabilidad y la velocidad de desarrollo de los procesos de agrietamiento. Los procesos de agrietamiento en ocasiones son superficiales y detectables, pero otras veces son menos evidentes y se encuentran en el interior del metal. Teniendo en cuenta lo anterior, se discuten las opciones de mantenimiento de reemplazo del componente, mantenimiento superficial del mismo, y mantenimiento interno. A continuación, se analizan las tres opciones.

Reemplazo del álabe: implica reemplazar el componente por uno nuevo e igual, en cuyo caso la condición 1, aplicada a todos los mecanismos sería suficiente para modelar esta acción de mantenimiento. Su efecto es el de un mantenimiento perfecto para el componente.

Mantenimiento superficial: se reparan simultáneamente sólo los mecanismos en la superficie del componente (picaduras, desgaste por fricción y erosión por goteo), asumiendo que la acción elimina completamente estos mecanismos, mientras que los mecanismos que actúan a un nivel más profundo en el material, como SCC, CF y fatiga, continúan su desarrollo, pero sin sus respectivos potenciadores. Es posible reparar superficialmente el álabe y llevada a cabo esta tarea, se espera que al menos todos los MD superficiales sean removidos. En este sentido no sería lógico asumir un mantenimiento para cada nucleador superficial, sino que los tres son eliminados simultáneamente y si se ejecuta bien, sus funciones de daño acumulado se restauran a cero, es decir, se asume mantenimiento perfecto para los mecanismos, que es diferente que asumir un mantenimiento perfecto para un componente completo. En el mantenimiento superficial se asume que los mecanismos de agrietamiento no son afectados directamente, sin embargo, debido a que sus mecanismos potenciadores han

desaparecido, los primeros sufren una modificación en la velocidad a la que se propagan en el siguiente ciclo.

Mantenimiento interno: Se reparan los mecanismos de agrietamiento (parte interna del componente), asumiendo un mantenimiento perfecto para cada uno. Note que, desde el punto de vista lógico, esta acción también termina aplicando mantenimiento a los mecanismos superficiales, ya que no se concibe que se repare una grieta, interna o superficial, dejando el componente con los mecanismos superficiales sin eliminar, sería una mala práctica. Dicho esto, se asume que los nucleadores superficiales también son reparados. El mantenimiento tiene entonces un efecto equivalente al remplazo del álabe, aunque sus naturalezas son diferentes.

Sintetizando, en el modelo se definen dos actividades de mantenimiento: interno y superficial. El interno actúa sobre todos los MD y es equivalente a un mantenimiento perfecto para el componente, o un reemplazo. El superficial solamente afecta los potenciadores Pic_MD, Got_MD y Fricc_MD.

5.6. Resultados del modelo

En esta sección se presentan diferentes gráficas que comparan los resultados del modelo propuesto para considerar las dependencias dinámicas de los MD con un modelo tradicional en el que se consideran todos los MD conectados directamente con la compuerta tope, es decir, sin considerar influencias.

Para generar los resultados fueron utilizados las mismas PI que en la Tabla 8 de la sección 4.5. Las distribuciones de probabilidad de los MD son del tipo Weibull, como se muestra en la Tabla 10.

Tabla 10: Parámetros para distribución de Weibull de los MD.

	Pic_MD	Got_MD	Fricc_MD	SCC_MD	Fatiga_MD	CF_MD
$W(forma; escala)$	$W(3; 15)$	$W(2; 17)$	$W(2; 15)$	$W(2; 20)$	$W(3; 17)$	$W(4; 20)$

En la Figura 23 se presentan los resultados del crecimiento de las probabilidades de los MD considerando que no existen influencias entre ellos y con dos mantenimientos, uno superficial y otro interno. El caso sería equivalente a unir cada MD de la Figura 22

directamente a la compuerta OR tope (excepto Fricc_MD), por lo que sería un AF tradicional con sus EB unidos por un OR. A los nombres de los MD dependientes se les añade entre paréntesis la palabra *leak*, significando que estas curvas no han sido influenciadas por los potenciadores.

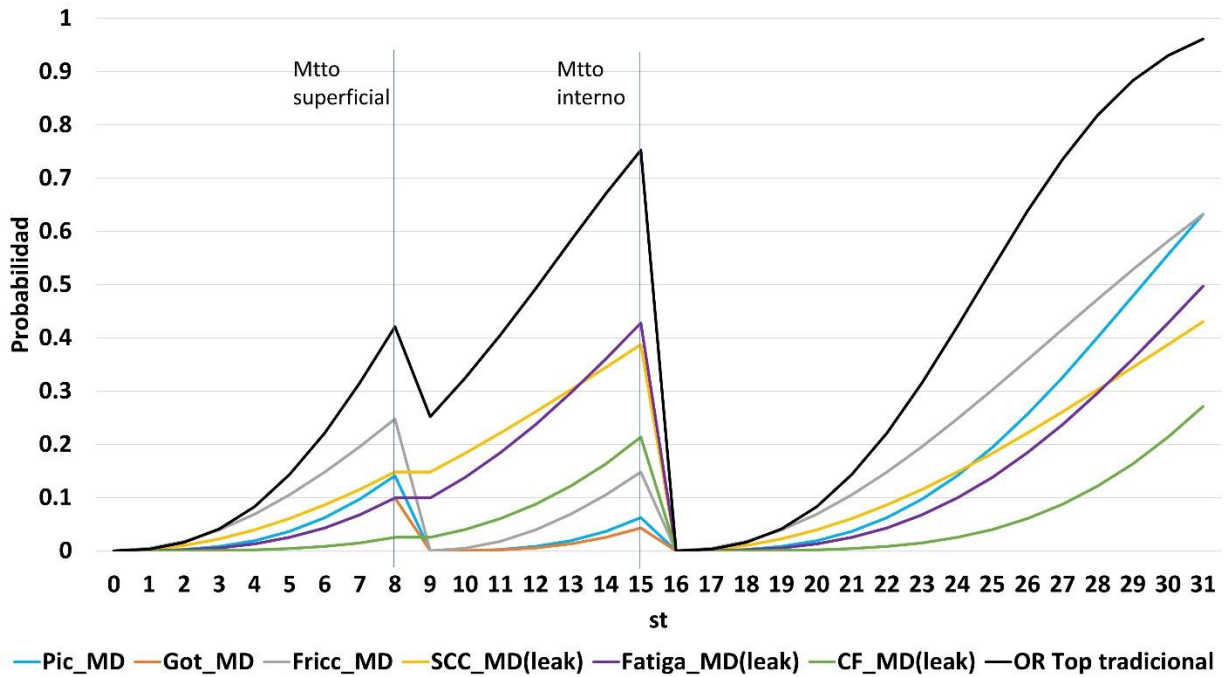


Figura 23: Distribuciones acumuladas para los MD y compuerta OR tope considerando independencias.

Bajo estas circunstancias, Fricc_MD no tiene ninguna influencia en el resultado (a pesar de que su curva se muestra en el gráfico) debido a que, con anterioridad, se asumió que este no produce el fallo del componente directamente, por lo que no se conecta a la compuerta OR tope. También, carecen de sentido las compuertas ERNOR, ya que, al no existir influencias, las FP de cada MD potenciador son desestimadas.

El efecto de los mantenimientos para los MD es consecuente con las condiciones 1 y 2 anteriormente explicadas. En el mantenimiento superficial, considerado cualitativamente como de peor calidad, solamente los mecanismos Pic_MD, Got_MD y Fricc_MD son restaurados. Los MD dependientes continúan su crecimiento según su distribución Weibull asignada. Existe un período de 1st de duración del mantenimiento, en el que no se produce crecimiento. La curva total, resultado de la compuerta OR tope, sí resulta en

una disminución debido a la desaparición total de los MD potenciadores, sin embargo, se nota que el resultado es el de un mantenimiento imperfecto para el componente porque los MD dependientes no se reestablecen. En el mantenimiento interno, considerado equivalente a uno perfecto, todas las FDA retornan a cero, dando por resultado un ciclo completamente nuevo para el componente.

La Figura 24 muestra el modelo considerando las dependencias entre los potenciadores, afectando los resultados de los MD dependientes. La diferencia fundamental resulta ser un incremento en las probabilidades de los MD dependientes debido a la influencia de los potenciadores, de acuerdo con las PI de las FP que se cuantifican mediante el modelo ERNOR dinámico. Esta influencia resulta en un incremento de la velocidad con la que sus FDA crecen en el tiempo. Para mejor claridad y diferencia con los resultados mostrados en la Figura 23, las curvas resultantes modificadas de los MD dependientes poseen un asterisco al final, mientras que las curvas para Pic_MD, Got_MD y Fricc_MD son iguales en ambas figuras.

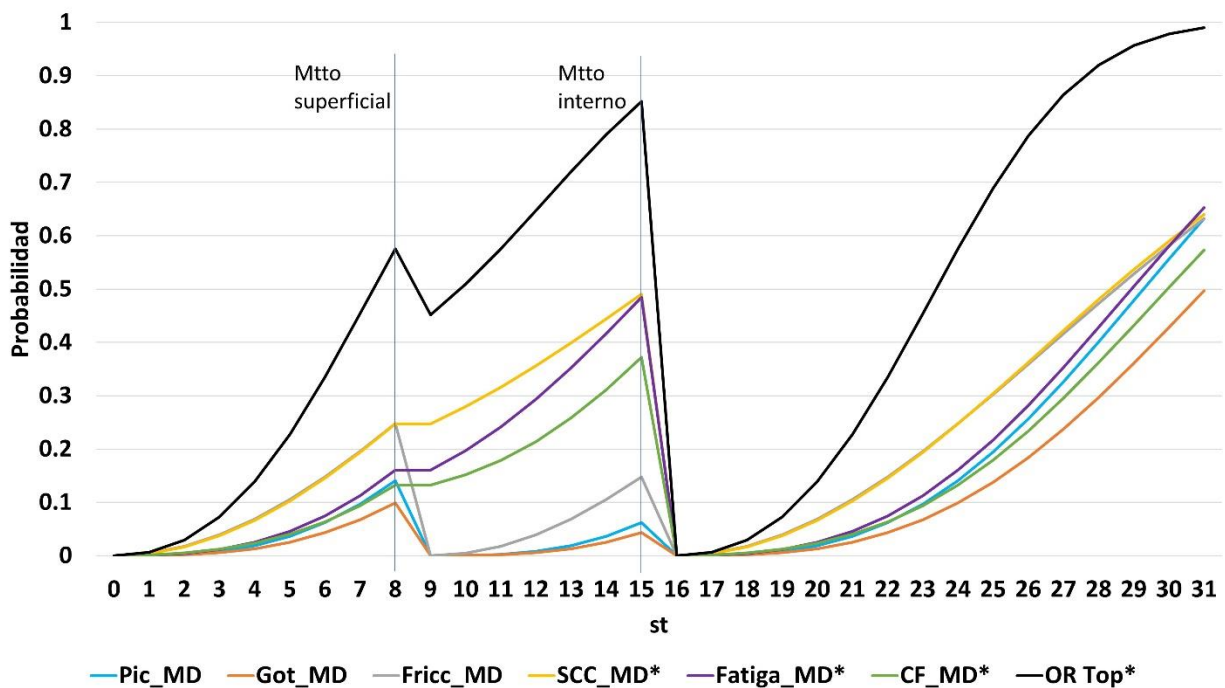


Figura 24: Distribuciones acumuladas para los MD y compuerta OR tope considerando las dependencias.

Con el objetivo de mostrar con mejor claridad el efecto neto de las consideraciones de independencia y dependencia entre los MD, se muestra la comparación de las compuertas tope de los ejemplos anteriores en la Figura 25.

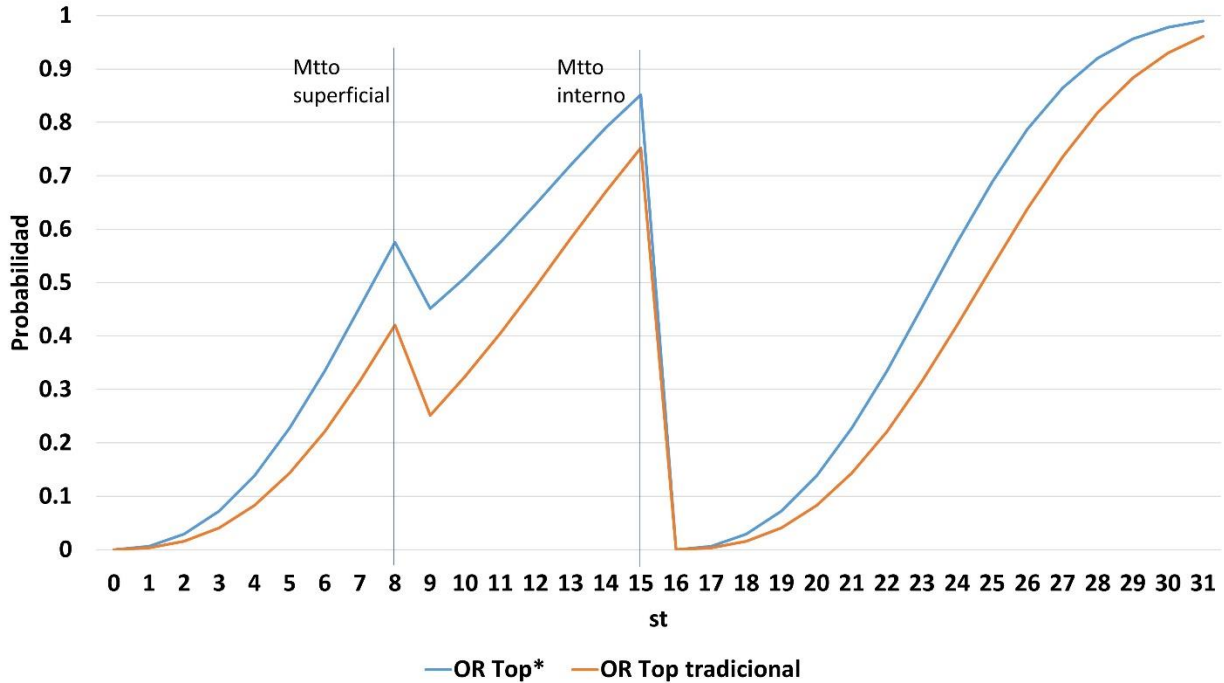


Figura 25: Comparación entre las compuertas OR tope, asumiendo independencia y dependencia entre los MD.

En la Figura 25 es visible el efecto que representan las dependencias en el modelo nuevo (serie: OR Top*). En palabras simples, la asunción de independencia (serie: Or Top tradicional) subestima la probabilidad de fallo de un componente que contiene varios MD que pueden interactuar entre sí. La única forma en que ambas curvas pueden coincidir es haciendo que todas las PI sean iguales a cero, lo cual se ha comprobado en el modelo y representa un resultado lógico porque es equivalente a anular el efecto de las compuestas ERNOR. Por lo tanto, se corrobora que los modelos que asumen independencia son casos particulares del nuevo modelo propuesto.

5.7. Resumen y conclusiones parciales: modelo para mecanismos de daño dependientes y dinámicos

En el presente capítulo se ha desarrollado un modelo dinámico para considerar las dependencias que existen entre los MD que coexisten dentro de un componente,

aumentando el nivel de granularidad de los análisis. Por tanto, el modelo propuesto se puede contemplar como un método para descomponer un elemento de ingeniería en sus MD, partiendo del conocimiento de las distribuciones probabilistas de cada uno actuando por sí solo, y agregándose mediante la compuerta ERNOR y probabilidades de influencia encuestadas a expertos. Se han propuesto estrategias de mantenimiento enfocadas en la eliminación de subconjuntos de MD del componente, lo cual permite modelar mantenimientos imperfectos. En este caso, se modelaron dos tipos de mantenimiento: el primero es el interno, equivalente a uno perfecto, restaurando todos los MD y sus influencias al estado como nuevo; el segundo se enfoca en los MD potenciadores que actúan a nivel superficial del componente. Dada la complejidad del modelo para ser manejado con los programas de RB disponibles para esta investigación, éste se implementó en una hoja de cálculo de Excel, incluyendo códigos de programación en VBA. De lo discutido en este capítulo se concluye que:

1. El método propuesto es un avance teórico en el campo de las herramientas para el cálculo de la probabilidad de fallo de sistemas complejos, como los AF, ya que propone un aumento en la granularidad de estos, llevándolos al nivel de MD, considerando sus dependencias de forma dinámica.
2. El nivel de granularidad alcanzado, hasta los MD, permite modelar actividades de mantenimiento imperfecto mediante la actuación directa sobre los MD modelados de forma diferenciada, pudiendo ser observado el efecto en las curvas de confiabilidad del componente luego de éstas.
3. Las dependencias dinámicas entre los MD se traducen en cambios en las funciones de daño de los MD dependientes y, por ende, de la curva de probabilidad de fallo total del componente. Lo anterior, al ser combinado con el nuevo enfoque de las acciones de mantenimiento, generan curvas acumuladas con formas complejas, por lo que no se consideró práctico determinar una forma analítica para la función de riesgo de los MD afectados y de la curva de probabilidad de fallo del componente.
4. La forma de considerar los mecanismos potenciadores, sus influencias sobre uno dependiente mediante las condiciones descritas, y los mantenimientos

propuestos, pueden ser utilizados como guía para construir una nueva compuerta lógica para análisis en AF.

5. El modelo se ha demostrado con los MD identificados para los álabes, sin embargo, al no ser implementado en una RB, no se han podido explotar sus capacidades de inferencia mediante la entrada de evidencias en diferentes puntos temporales para los MD. Por tanto, el modelo dinámico tiene un enfoque predictivo por naturaleza, es decir, solamente se modelan las consecuencias en términos de probabilidad de fallo dadas las condiciones iniciales y los mantenimientos en determinados puntos temporales. Por esta misma razón, no se consideraron las variables de ubicación.
6. La no consideración de las dependencias (cuando existen) entre los MD que afectan la confiabilidad de un componente, pueden influir en los cálculos de la probabilidad de fallo, subestimándola, por lo que se confirma la sub-hipótesis planteada al inicio del capítulo.

Resumen y Conclusiones Generales

En la presente tesis se han estudiado los mecanismos de daño que comúnmente afectan los álabes rotatorios de las turbinas de vapor nucleares. Se desarrollaron dos modelos probabilísticos, cada uno con diferentes objetivos, potencialidades y limitaciones, pero que entre ambos se complementan; se les llama, modelo estático y dinámico, respectivamente. A continuación, se ofrecen las conclusiones generales de la presente tesis:

1. Los MD que afectan a los álabes de las turbinas son condicionalmente dependientes en términos probabilísticos, de la presencia de otros MD, de la fila de los álabes y de la parte del álabe que se esté analizando.
2. Las RB han demostrado ser una herramienta adecuada para modelar, de manera estática, las dependencias condicionales que se establecen entre los MD, los MF que generan y las variables de ubicación; sin embargo, no fueron efectivas para el mismo propósito, pero considerando el tiempo. El modelo dinámico introduce en las RB o RBD, demasiadas combinaciones difíciles de cuantificar con los programas computacionales disponibles, problemas de discretización de funciones de distribución acumuladas como la Weibull y, además, el mantenimiento diferenciado para cada MD no pudo ser implementado.
3. Como parte del proceso de cuantificación de los modelos estático y dinámico, se desarrolló el ERNOR, una versión Extendida del *Recursive Noisy OR*. En él se resuelve el problema de la asimetría cuando la cantidad de causas de un efecto excede tres. Además de ser un método nuevo para calcular probabilidades puntuales sinérgicas para evaluar combinaciones desconocidas de una TPC, su versión dinámica genera funciones de distribución acumuladas de las probabilidades conjuntas de dichas causas. El ERNOR es una contribución directa al estado del arte de los métodos de cuantificación de probabilidades conjuntas a partir de combinaciones más fáciles de encuestar a expertos. Futuro trabajo es desarrollar transformaciones para introducir probabilidades conjuntas dependientes del tiempo para más de tres causas.

Conclusiones específicas para el modelo estático

4. El modelo estático, basado en RB es una herramienta que permite realizar diferentes análisis para ayudar en la identificación y ubicación de los MD que contribuyen a los fallos a partir de la evidencia que surge durante el mantenimiento o suposiciones del analista. Con este fin, el modelo de RB considera las dependencias probabilísticas condicionales entre los MD, MF y la susceptibilidad de las diferentes ubicaciones de los álabes.
5. Con el objetivo de cuantificar el modelo estático, se ha desarrollado un nuevo método de cálculo para sus TPC basado en el juicio de expertos. Combina el ERNOR con un proceso de clasificación de la susceptibilidad de las diferentes ubicaciones de los álabes dentro de la turbina a los MD identificados.
6. El modelo estático proporciona un nivel refinado de granularidad a nivel de fila de álabes, partes de estos y los MD que producen los MF. Proporciona información detallada para la identificación y el mejor entendimiento de los MD, lo cual permite enfocar las subsecuentes actividades de mantenimiento con fundamento en los resultados de la propagación de la evidencia introducida en la red.
7. El modelo estático posee la limitación de no considerar el tiempo de forma explícita, por lo que no es posible visualizar la evolución de los MD en el tiempo. Su cuantificación depende de la disponibilidad de expertos en turbinas que llenen el cuestionario donde se recopilan los datos de entrada, debido a la escasez de datos estadísticos a nivel de fila, parte de álabes y los MD que los afectan.

Conclusiones específicas para el modelo dinámico

8. El modelo dinámico considera los MD y sus influencias, teniendo en cuenta el tiempo, así como la introducción de estrategias de mantenimiento enfocadas a cada MD por separado. Este nuevo enfoque de mantenimiento implica que dichas acciones tienen un efecto de reparación imperfecta a nivel de componente, debido a que el mantenimiento puede actuar sobre subconjuntos de MD, afectando la velocidad de desarrollo del fallo mediante otros MD que persisten con funciones de riesgo modificadas. Para la consideración de las dependencias dinámicas entre los MD se utilizó el ERNOR en su versión dinámica.

9. El modelo dinámico, al no ser manejable por una RB, fue implementado en una hoja de cálculo, y los efectos de los mantenimientos fueron programados en Visual Basic para Aplicaciones debido al grado de complejidad.
10. El modelo dinámico se considera un avance teórico en el campo de las herramientas para el cálculo de la probabilidad de fallo de sistemas complejos, como los árboles de fallo, ya que propone un aumento en la granularidad de estos, llevándolos al nivel de MD, considerando sus dependencias de forma dinámica.
11. La no consideración de las dependencias (cuando existen) entre los MD que afectan la confiabilidad de un componente, pueden influir en los cálculos de la probabilidad de fallo, subestimándola. Por tanto, el modelo dinámico ofrece resultados más precisos con curvas de probabilidad acumuladas complejas sólo obtenibles mediante la consideración de los MD, sus dependencias dinámicas y los mantenimientos enfocados en MD individuales.
12. El modelo dinámico parte de la consideración de que se conoce previamente la función de distribución de probabilidad de cada MD por separado (sin influencia de otros MD modelados). Dichas funciones pueden ser estimadas por diversos métodos (estadística de operación o análisis de laboratorio) que no están dentro del alcance de este estudio.

Conclusiones aplicables a ambos modelos

13. Ambos modelos se complementan en sus capacidades de análisis dadas las limitaciones de cada uno y las necesidades de modelación del analista. Mientras que el modelo estático no considera la variable temporal, ofrece la posibilidad de realizar inferencias para determinar las causas más probables de un fallo, y las ubicaciones más susceptibles dentro de la turbina. El modelo dinámico no ofrece tales capacidades, pero genera curvas de probabilidad de fallo a partir de las influencias dinámicas de los MD con la capacidad de incorporar mantenimientos imperfectos diferenciados para cada MD. A diferencia del modelo estático, el dinámico se presenta sin considerar las variables de ubicación, por lo que las distribuciones probabilísticas de cada MD y sus probabilidades de influencia corresponderían a una combinación de ubicación específica. En este sentido, el

modelo dinámico puede usarse para evaluar las estrategias de mantenimiento para las ubicaciones más susceptibles obtenidas del modelo estático ante la evidencia disponible.

14. El juicio de expertos ha sido la fuente de información fundamental, condicionando la forma de cuantificar ambos modelos. La información de los fallos con el grado de granularidad requerido en ambos modelos no es de fácil acceso o inexistente.
15. Los modelos desarrollados son generalizables y extensibles a otros sistemas. El modelo estático puede ser aplicado en otros sectores industriales que utilizan turbinas, independientemente de la tecnología (nuclear, fósil), el fluido de trabajo (gas, vapor), el propósito (aviación, producción de energía, procesos industriales) y la cantidad de filas de álabes. El modelo dinámico puede ser incorporado en su totalidad como una nueva compuerta lógica en herramientas de ingeniería confiabilidad como los AF para considerar distribuciones probabilísticas asociadas a los MD de un componente y acciones de mantenimiento imperfectas.
16. Los resultados obtenidos de ambos modelos y su forma de implementación permiten confirmar la hipótesis planteada al inicio porque en efecto: se ha logrado un nivel de granularidad que ha permitido demostrar cómo los resultados del modelo estático pueden ser utilizados para identificar los MD que más contribuyen a los fallos y su relación con las ubicaciones más susceptibles; en el modelo dinámico se demuestra cómo efectivamente ocurre una subestimación de la probabilidad de fallo en caso de no considerarse las dependencias dinámicas de los MD; y cómo el método de mantenimiento a cada MD individual ofrece flexibilidad para manejar estrategias de mantenimiento imperfecto a nivel de componente.

El trabajo futuro se concentrará en unificar ambos modelos, es decir, encontrar la forma de introducir el modelo dinámico dentro de una RB para concentrar las capacidades de ambos en una única y compacta herramienta.

Referencias

- [1] R. P. Dewey y N. F. Rieger, "Survey of steam turbine blade failures", EPRI-CS-3891, Palo Alto, CA, 1985.
- [2] M. Zhang, Y. Liu, W. Wang, P. Wang, y J. Li, "The fatigue of impellers and blades", *Eng. Fail. Anal.*, vol. 62, pp. 208–231, 2016.
- [3] L. K. Bhagi, P. Gupta, y V. Rastogi, "A Brief Review on Failure of Turbine Blades", en *Proceedings STME-2013 Smart Technologies for Mechanical Engineering*, 2013, núm. October, pp. 1–8.
- [4] M. O. Speidel, J. Denj, y B. Scarlin, "Stress corrosion cracking and corrosion fatigue of steam-turbine rotor and blade materials", Luxembourg, 1991.
- [5] D. W. Gandy, S. J. Findland, J. T. Stover, M. Breslin, S. Allgood, y E. V. Clark, "State-of-the-Art Weld Repair Technology for Rotating Components. Volume 2: Repair of Steam Turbine Blading", TR-107021, EPRI, Palo Alto, CA, 1997.
- [6] EPRI, *Turbine Steam Path Damage: Theory and Practice. Volume 1: Turbine Fundamentals*. Palo Alto, EPRI, 1999.
- [7] S. D. Cramer y B. S. Covino, Eds., *Corrosion: Fundamentals, Testing, and Protection*, vol. 13A. ASM International, 2003.
- [8] W. P. Sanders, *Turbine Steam Path. Maintenance and Repair*, vol. 1. PennWell Corp, 2001.
- [9] W. P. Sanders, *Turbine Steam Path. Maintenance and Repair*, vol. 2. PennWell Corp, 2002.
- [10] A. S. Leyzerovich, *Wet-Steam Turbines for Nuclear Power Plants*. PennWell Corp, 2005.
- [11] EPRI, "Development of Code to Predict Stress Corrosion Cracking and Corrosion Fatigue of Low Pressure Turbine Components", Palo Alto, CA: 2004. 1004190.

- [12] EPRI, “Development of Model to Predict Stress Corrosion Cracking and Corrosion Fatigue of Low Pressure Turbine Components”, Palo Alto, CA: 2007. 1012204.
- [13] EPRI, “Integration of Component Stress Analysis with EPRI Steam Turbine Corrosion Modeling Software”, Palo Alto, CA: 2005. 1011937.
- [14] EPRI, “Descriptions of Past Research: EPRI Fossil and Nuclear Steam Turbines-Generators and Auxiliary Systems”, EPRI, Palo Alto, CA: 2017. 3002011414.
- [15] “EPRI Home”. [En línea]. Disponible en: <https://www.epri.com/?lang=en-US>. [Consultado: 19-jun-2019].
- [16] T. Machniewicz, “Fatigue crack growth prediction models for metallic materials Part I: Overview of prediction concepts”, *Fatigue Fract. Eng. Mater. Struct.*, vol. 36, pp. 293–307, 2012.
- [17] P. Měšťánek, “Low cycle fatigue analysis of a last stage steam turbine blade”, *Appl. Comput. Mech.*, vol. 2, pp. 71–82, 2008.
- [18] T. J. Christ, M. J. Drosjack, y M. G. Tanner, “Steam Turbine Risk Assessment-A tool to assist in optimizing inspection and overhauls of industrial steam turbines”, en *26th Turbomachinery Symposium*, 1997, p. 8.
- [19] Impact Technologies LLC, “BladePro-AF™ and BladePro-CF™”. 2010.
- [20] STI Technologies Inc., “BLADE-ST™ The Complete Steam Turbine Blade Analysis Tool”. 1998.
- [21] EPRI, “Development of an LP Rotor Rim-Attachment Cracking Life Assessment Code (LPRimLife)”, Palo Alto, CA: 1999. TR-110407.
- [22] T. H. McCloskey, “Troubleshooting Turbine Steam Path Damage”, en *31st. Turbomachinery Symposium*, 2002, pp. 105–144.
- [23] EPRI, “Life Cycle Management Planning Sourcebooks. Volume 8: Main Turbine”, Palo Alto, CA 1009071, 2004.

- [24] Q. Zhou *et al.*, “Water Drop Erosion on Turbine Blades: Numerical Framework and Applications”, *Mater. Trans. JIM*, vol. 49, núm. 7, pp. 1606–1615, 2008.
- [25] S. Soni, “Analysis of Liquid Droplet Erosion For Steam Turbine Blades of Composite Material”, *Int. J. Mech. Eng. Robot. Res.*, vol. 1, núm. 3, pp. 214–226, 2012.
- [26] M. Ahmad, M. Casey, y N. Sürken, “Experimental assessment of droplet impact erosion resistance of steam turbine blade materials”, *Wear*, vol. 267, núm. 9–10, pp. 1605–1618, 2009.
- [27] G. Ilieva, “Mechanisms of water droplets deposition on turbine blade surfaces and erosion wear effects”, *J. Appl. Fluid Mech.*, vol. 10, núm. 2, pp. 551–567, 2017.
- [28] S. Zhou y A. Turnbull, “Steam Turbine Operating Conditions, Chemistry of Condensates, and Environment Assisted Cracking – A Critical Review”, 2002.
- [29] EPRI, “Steam Turbine Blade Failure Root Cause Analysis Guide”, EPRI, Palo Alto, CA 1014137, 2008.
- [30] R. Salzman *et al.*, “Corrosion-Fatigue Prediction Methodology for 12 % Cr Steam Turbine Blades”, en *ASME 2013 Power Conference*, 2013, pp. 1–13.
- [31] W. Glaeser y I. G. Wright, “Forms of Mechanically Assisted Degradation”, en *ASM Handbook Volume 13A: Corrosion: Fundamentals, Testing, and Protection*, ASM International, 2003, pp. 322–330.
- [32] M. Katinić, D. Kozak, I. Gelo, y D. Damjanović, “Corrosion fatigue failure of steam turbine moving blades: A case study”, *Eng. Fail. Anal.*, vol. 106, núm. July, 2019.
- [33] L. K. Bhagi, V. Rastogi, y P. Gupta, “Study of corrosive fatigue and life enhancement of low pressure steam turbine blade using friction dampers”, *J. Mech. Sci. Technol.*, vol. 31, núm. 1, pp. 17–27, 2017.
- [34] T. Hattori, V. T. Kien, y M. Yamashita, “Fretting fatigue life estimations based on fretting mechanisms”, *Tribol. Int.*, vol. 44, núm. 11, pp. 1389–1393, 2011.

- [35] F. Xue, Z.-X. Wang, W.-S. Zhao, X.-L. Zhang, B.-P. Qu, y L. Wei, "Fretting fatigue crack analysis of the turbine blade from nuclear power plant", *Eng. Fail. Anal.*, vol. 44, pp. 299–305, 2014.
- [36] W. Zhao, Y. Li, M. Xue, P. Wang, y J. Jiang, "Vibration analysis for failure detection in low pressure steam turbine blades in nuclear power plant", *Eng. Fail. Anal.*, vol. 84, núm. October 2017, pp. 11–24, 2018.
- [37] EPRI, "Turbine Condition Assessment and Monitoring Methodology", Palo Alto, CA 1004963, 2006.
- [38] EPRI, "Steam Turbine On-Line Blade Condition Assessment", EPRI, Palo Alto, CA: 2008. 1014143.
- [39] A. A. Gubran y J. K. Sinha, "Shaft instantaneous angular speed for blade vibration in rotating machine", *Mech. Syst. Signal Process.*, vol. 44, núm. 1–2, pp. 47–59, 2014.
- [40] EPRI, "Noncontacting Detection of Turbine Blade Vibration: Technology Assesment", EPRI, Palo Alto, CA: 2002. 1004559.
- [41] EPRI, "Infrared Probe for Application to Steam Turbine Blade Vibration Detection", Palo Alto, CA: 2004. 1004961.
- [42] EPRI, "Interim Guidelines for In Situ Visual Inspection of Inlet and Outlet Turbine Stages: Part 2: Experiences, Approaches and Improvements in Remote Visual Inspection", Palo Alto, CA TR-114961, 2000.
- [43] EPRI, "Interim Guidelines for In-Situ Inspection and Monitoring Techniques for Steam Turbines Volume 1: An Overview of Remote Visual Inspection", Palo Alto, CA TR-113996-V1, 1999.
- [44] J. Pearl, *Causality: Models, reasoning, and inference*. Cambridge University Press, 2009.
- [45] K. B. Korb y A. E. Nicholson, *Bayesian Artificial Intelligence*. Boca Raton:

- CHAPMAN & HALL/CRC, 2004.
- [46] P. Weber, G. Medina-Oliva, C. Simon, y B. lung, “Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas”, *Eng. Appl. Artif. Intell.*, vol. 25, núm. 4, pp. 671–682, 2012.
- [47] S. Kabir y Y. Papadopoulos, “Applications of Bayesian networks and Petri nets in safety, reliability, and risk assessments: A review”, *Saf. Sci.*, vol. 115, núm. February, pp. 154–175, 2019.
- [48] B. Cai, L. Huang, y M. Xie, “Bayesian Networks in Fault Diagnosis”, *IEEE Trans. Ind. Informatics*, vol. 13, núm. 5, pp. 2227–2240, 2017.
- [49] B. Cai *et al.*, “Application of Bayesian Networks in Reliability Evaluation”, *IEEE Trans. Ind. Informatics*, vol. 15, núm. 4, pp. 2146–2157, 2018.
- [50] S. Chen, Z. Qi, D. Chen, L. Guo, y W. Peng, “Investigation of Bayesian network for reliability analysis and fault diagnosis of complex systems with real case applications”, *Adv. Mech. Eng.*, vol. 9, núm. 10, pp. 1–18, 2017.
- [51] D. Özgür-Ünlüakın y T. Bilgiç, “Replacement policies for a complex system with unobservable components using dynamic Bayesian networks”, *Int. J. Comput. Intell. Syst.*, vol. 7, núm. sup1, pp. 68–83, ene. 2014.
- [52] D. Özgür-Ünlüakın, B. Türkali, A. Karacaörenli, y S. Çağlar Aksezer, “A DBN based reactive maintenance model for a complex system in thermal power plants”, *Reliab. Eng. Syst. Saf.*, vol. 190, núm. May, p. 106505, 2019.
- [53] M. C. Darling, G. F. Luger, T. B. Jones, M. R. Denman, y K. M. Groth, “Intelligent Modeling for Nuclear Power Plant Accident Management”, *Int. J. Artif. Intell. Tools*, vol. 27, núm. 2, 2018.
- [54] K. M. Groth y A. Mosleh, “Deriving causal Bayesian networks from human reliability analysis data: A methodology and example model”, *Proc. Inst. Mech. Eng. Part O J. Risk Reliab.*, vol. 226, núm. 4, pp. 361–379, 2012.

- [55] M. Ashraf, H. Davoudpour, y V. Khodakarami, "A Bayesian Network to Ease Knowledge Acquisition of Causal Dependence in CREAM: Application of Recursive Noisy-OR Gates", *Qual. Reliab. Eng. Int.*, vol. 33, núm. 3, pp. 479–491, 2016.
- [56] K. Zwirgmaier, D. Straub, y K. M. Groth, "Capturing cognitive causal paths in human reliability analysis with Bayesian network models", *Reliab. Eng. Syst. Saf.*, vol. 158, pp. 117–129, 2017.
- [57] F. Ayello, S. Jain, N. Sridhar, y G. H. Koch, "Quantitive assessment of corrosion probability-A Bayesian network approach", *Corrosion*, vol. 70, núm. 11, pp. 1128–1147, 2014.
- [58] G. Liu, F. Ayello, J. Zhang, y P. Stephens, "The Application of Bayesian Network Threat Model for Corrosion Assessment of Pipeline in Design Stage", en *Proceedings of the 2018 12th International Pipeline Conference IPC2018*, 2018.
- [59] G. Kabir, S. Tesfamariam, A. Francisque, y R. Sadiq, "Evaluating risk of water mains failure using a Bayesian belief network model", *Eur. J. Oper. Res.*, vol. 240, núm. 1, pp. 220–234, 2015.
- [60] C. Karlsson, J. Arriagada, y M. Genrup, "Detection and interactive isolation of faults in steam turbines to support maintenance decisions", *Simul. Model. Pract. Theory*, vol. 16, núm. 10, pp. 1689–1703, 2008.
- [61] M. Sýkora, J. Marková, y D. Diamantidis, "Bayesian network application for the risk assessment of existing energy production units", *Reliab. Eng. Syst. Saf.*, vol. 169, núm. March 2017, pp. 312–320, 2018.
- [62] D. N. Dongiovanni y T. Ilesmantas, "Failure rate modeling using fault tree analysis and Bayesian network: DEMO pulsed operation turbine study case", *Fusion Eng. Des.*, vol. 109–111, pp. 613–617, 2016.
- [63] A. M. Mirhosseini, S. Adib Nazari, A. Maghsoud Pour, S. Etemadi Haghighi, y M. Zareh, "Probabilistic failure analysis of hot gas path in a heavy-duty gas turbine

- using Bayesian networks”, *Int. J. Syst. Assur. Eng. Manag.*, vol. 10, núm. 5, pp. 1173–1185, 2019.
- [64] J. Hu, L. Zhang, L. Ma, y W. Liang, “An integrated safety prognosis model for complex system based on dynamic Bayesian network and ant colony algorithm”, *Expert Syst. Appl.*, vol. 38, núm. 3, pp. 1431–1446, 2011.
- [65] J. Cain, *Planning improvements in natural resources management. Guidelines for using Bayesian networks to support the planning and management of development programmes in the water sector and beyond*. Wallingford, Centre for Ecology and Hydrology, 2001.
- [66] Z. Tang y B. McCabe, “Developing complete conditional probability fractional data for bayesian belief networks”, *J. Comput. Civ. Eng.*, vol. 21, núm. 4, pp. 265–276, 2007.
- [67] B. W. Wisse, S. P. van Gosliga, N. P. van Elst, y A. I. Barros, “Relieving the elicitation burden of Bayesian Belief Networks”, en *Sixth Bayesian modelling applications workshop on UAI*, 2008.
- [68] W. Røed, A. Mosleh, J. E. Vinnem, y T. Aven, “On the use of the hybrid causal logic method in offshore risk analysis”, *Reliab. Eng. Syst. Saf.*, vol. 94, núm. 2, pp. 445–455, 2009.
- [69] K. Chin, D. Tang, J. Yang, S. Y. Wong, y H. Wang, “Assessing new product development project risk by Bayesian network with a systematic probability generation methodology”, *Expert Syst. Appl.*, vol. 36, núm. 6, pp. 9879–9890, 2009.
- [70] K. F. R. Liu, J. Y. Kuo, K. Yeh, C. W. Chen, H. H. Liang, y Y. H. Sun, “Using fuzzy logic to generate conditional probabilities in Bayesian belief networks: a case study of ecological assessment”, *Int. J. Environ. Sci. Technol.*, vol. 12, núm. 3, pp. 871–884, 2015.
- [71] N. E. Fenton, M. Neil, y J. G. Caballero, “Using Ranked Nodes to Model

- Qualitative Judgments in Bayesian Networks”, *IEEE Trans. Knowl. Data Eng.*, vol. 19, núm. 10, pp. 1420–1432, 2007.
- [72] P. Laitila y K. Virtanen, “Improving Construction of Conditional Probability Tables for Ranked Nodes in Bayesian Networks”, *Trans. Knowl. Data Eng.*, vol. 28, núm. 7, pp. 1691–1705, 2016.
- [73] P. Laitila y K. Virtanen, “On Theoretical Principle and Practical Applicability of Ranked Nodes Method for Constructing Conditional Probability Tables of Bayesian Networks”, *Trans. Syst. Man, Cybern. Syst.*, vol. 50, núm. 5, pp. 1943–1955, 2020.
- [74] L. Mkrtchyan, L. Podofillini, y V. N. Dang, “Bayesian belief networks for human reliability analysis: A review of applications and gaps”, *Reliab. Eng. Syst. Saf.*, vol. 139, pp. 1–16, 2015.
- [75] L. Mkrtchyan, L. Podofillini, y V. N. Dang, “Methods for building Conditional Probability Tables of Bayesian Belief Networks from limited judgment: An evaluation for Human Reliability Application”, *Reliab. Eng. Syst. Saf.*, vol. 151, pp. 93–112, 2016.
- [76] G. Zhang y V. V. Thai, “Expert elicitation and Bayesian Network modeling for shipping accidents: A literature review”, *Saf. Sci.*, vol. 87, pp. 53–62, 2016.
- [77] C. Werner, T. Bedford, R. M. Cooke, A. M. Hanea, y O. Morales-Nápoles, “Expert judgement for dependence in probabilistic modelling: A systematic literature review and future research directions”, *Eur. J. Oper. Res.*, vol. 258, núm. 3, pp. 801–819, 2017.
- [78] J. Pearl, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, 2a ed. Morgan Kaufmann Publishers Inc., 1988.
- [79] F. J. Díez y M. J. Druzdzel, “Canonical Probabilistic Models for Knowledge Engineering”, Technical Report CISIAD-06-01, Version 0.9, 2007.
- [80] A. Oniśko, M. J. Druzdzel, y H. Wasyluk, “Learning Bayesian network parameters

- from small data sets: application of Noisy-OR gates”, *Int. J. Approx. Reason.*, vol. 27, pp. 165–182, 2001.
- [81] F. J. Díez, “Parameter adjustment in Bayes networks. The generalized noisy OR-gate”, en *Uncertainty in Artificial Intelligence*, 1993, pp. 99–105.
- [82] A. Zagorecki y M. J. Druzdzel, “Knowledge Engineering for Bayesian Networks: How Common Are Noisy-MAX Distributions in Practice?”, *Trans. Syst. Man, Cybern. Syst.*, vol. 43, núm. 1, pp. 186–195, 2013.
- [83] Y. Xiang y N. Jia, “Modeling Causal Reinforcement and Undermining for Efficient CPT Elicitation”, *IEEE Trans. Knowl. Data Eng.*, vol. 19, núm. 12, pp. 1708–1718, 2007.
- [84] Y. Xiang, “Non-impeding noisy-AND tree causal models over multi-valued variables”, *Int. J. Approx. Reason.*, vol. 53, núm. 7, pp. 988–1002, 2012.
- [85] Y. Xiang y Y. Jin, “Efficient probabilistic inference in Bayesian networks with multi-valued NIN-AND tree local models”, *Int. J. Approx. Reason.*, vol. 87, pp. 67–89, 2017.
- [86] Y. Xiang y M. Truong, “Acquisition of Causal Models for Local Distributions in Bayesian Networks”, *IEEE Trans. Cybern.*, vol. 44, núm. 9, pp. 1591–1604, 2014.
- [87] Y. Xiang, “Direct causal structure extraction from pairwise interaction patterns in NAT modeling Bayesian networks”, *Int. J. Approx. Reason.*, vol. 105, pp. 175–193, 2019.
- [88] G. Fallet-Fidry, P. Weber, C. Simon, B. lung, y C. Duval, *Evidential network-based extension of Leaky Noisy-OR structure for supporting risks analyses*, vol. 45, núm. 20. IFAC, 2012.
- [89] K. Zhou, A. Martin, y Q. Pan, “The Belief Noisy-OR Model Applied to Network Reliability Analysis”, *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 24, núm. 6, pp. 937–960, 2016.

- [90] A. T. Zagorecki, "Local Probability Distributions in Bayesian Networks: Knowledge Elicitation and Inference", University of Pittsburgh, 2010.
- [91] A. L. Madsen y B. D'Ambrosio, "A Factorized Representation of Independence of Causal Influence and Lazy Propagation", *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 8, núm. 2, pp. 151–165, 2000.
- [92] J. F. Lemmer y D. E. Gossink, "Recursive noisy OR - A Rule for Estimating Complex Probabilistic Interactions", *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 34, núm. 6, pp. 2252–2261, 2004.
- [93] R. Chang, W. Brauer, y M. Stetter, "Modeling semantics of inconsistent qualitative knowledge for quantitative Bayesian network inference", *Neural Networks*, vol. 21, núm. 2–3, pp. 182–192, 2008.
- [94] M. Henrion, "Some Practical Issues in Constructing Belief Networks", en *Uncertainty in Artificial Intelligence*, 1989, pp. 161–173.
- [95] S. P. D. Woudenberg, L. C. Van Der Gaag, y C. M. A. Rademaker, "An intercausal cancellation model for Bayesian-network engineering", *Int. J. Approx. Reason.*, vol. 63, pp. 32–47, 2015.
- [96] D. Gossink, M. Shahin, J. Lemmer, y I. Fuss, "A practical approach to Dynamic Bayesian Networks", en *2007 Information, Decision and Control*, 2007, pp. 71–77.
- [97] B. M. Schönbauer, A. Perlega, y S. E. Stanzl-Tschegg, "Pit-to-crack transition and corrosion fatigue of 12% Cr steam turbine blade steel", en *13th International Conference on Fracture*, 2013.
- [98] P. R. Roberge, "Statistical Interpretation of Corrosion Test Results", en *ASM Handbook, Volume 13A: Corrosion: Fundamentals, Testing, and Protection*, 2003, pp. 425–429.
- [99] P. S. Pao, R. A. Bayles, y G. R. Yoder, "Effect of Ripple Load on Stress-Corrosion Cracking in Structural Steels", *J. Eng. Mater. Technol.*, vol. 113, núm. January 1991, pp. 125–129, 1991.

- [100] “BayesFusion, LLC”. [En línea]. Disponible en: <https://www.bayesfusion.com/>.
- [101] U. S. NRC, “Guidance on the Treatment of Uncertainties Associated with PRAs in Risk-Informed Decisionmaking. NUREG-1855”, 2017.
- [102] S. L. Lauritzen, “The EM algorithm for graphical association models with missing data”, *Comput. Stat. Data Anal.*, vol. 19, núm. 2, pp. 191–201, 1995.
- [103] B. Jones, I. Jenkinson, Z. Yang, y J. Wang, “The use of Bayesian network modelling for maintenance planning in a manufacturing industry”, *Reliab. Eng. Syst. Saf.*, vol. 95, núm. 3, pp. 267–277, 2010.
- [104] D. R. Cox, “Regression Models and Life-Tables”, *J. R. Stat. Soc. Ser. B*, vol. 34, núm. 2, pp. 187–202, 1972.
- [105] D. R. Cox y D. Oakes, *Analysis of Survival Data*. New York: Chapman & Hall, 1984.
- [106] J. A. Nachlas, *Reliability engineering. Probabilistic models and maintenance methods*, 2a ed. CRC Press, 2017.
- [107] N. D. Singpurwalla, “Survival in Dynamic Environments”, *Stat. Sci.*, vol. 10, núm. 1, pp. 86–103, 1995.
- [108] T. Nakagawa, “Imperfect Preventive-Maintenance”, *IEE Trans. Reliab.*, vol. 28, núm. 5, p. 402, 1979.
- [109] M. Brown y F. Proschan, “Imperfect Repair”, *J. Appl. Probab.*, vol. 20, núm. 4, pp. 851–859, 1983.
- [110] M. A. K. Malik, “Reliable preventive maintenance scheduling”, *AIEE Trans.*, vol. 11, núm. 3, pp. 221–228, 1979.
- [111] M. Kijima, “Some Results for Repairable Systems with General Repair”, *J. Appl. Probab.*, vol. 26, núm. 1, pp. 89–102, 1989.
- [112] F. Zhang y A. K. S. Jardine, “Optimal maintenance models with minimal repair ,

periodic overhaul and complete renewal”, *IEE Trans.*, vol. 30, pp. 1109–1119, 1998.

- [113] A. Lisnianski, I. Frenkel, y Y. Ding, *Multi-state System Reliability Analysis and Optimization for Engineers and Industrial Managers*. Springer, 2010.

Anexo A: Encuesta de datos para evaluar el impacto de los mecanismos de daño en los álabes de turbinas de vapor

Introducción

Se ha desarrollado un modelo para ayudar a identificar los mecanismos de daño y los modos de fallo en los álabes rotatorios de las turbinas de vapor de baja presión. El modelo proporciona varios beneficios: 1) al asociar modos de fallo (por ejemplo, un álabe agrietado), sus mecanismos de daño más probables y las ubicaciones susceptibles, se logra un nivel de granularidad con información más detallada para la toma de decisiones de mantenimiento en sus subsecuentes etapas; 2) se pueden realizar análisis basados en conjeturas del analista, lo que permite anticipar las acciones de mantenimiento antes de una parada programada; y 3) las observaciones realizadas durante las inspecciones se pueden agregar al modelo, mejorando su precisión.

Un primer paso necesario, y el motivo de esta encuesta, es la aportación del “juicio de expertos”, para cuantificar un modelo de red bayesiana (Figura 26). El modelo representa las interacciones entre los mecanismos de daño (MD) más comunes (nodos verdes), los modos de fallo (MF) a los que tributan (nodos azules), el tipo de paro de la turbina (nodo gris) y las ubicaciones de los álabes dentro de la turbina (fila de álabes y sus partes o porciones, los nodos amarillos).

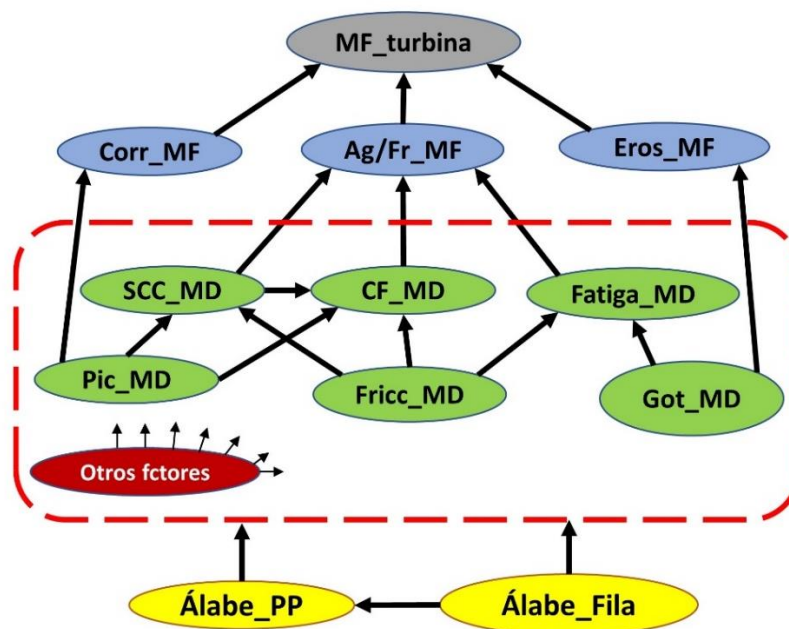


Figura 26: Modelo simplificado de la red bayesiana.

Las turbinas de vapor se componen de varias filas de álabes, siendo la fila L-0 la última, antes de salir al condensador, compuesta por los álabes más grandes (Figura 27A), y cada álabes se divide en componentes (Figura 27B). Estos identificadores de fila y partes/porciones de los álabes se utilizan en toda la encuesta.




Figura 27: (A) Sección transversal de una turbina de baja presión, mostrando las filas de álabes. (B) Partes o porciones de un álabes.

Las preguntas siguientes asumen una turbina de nueve filas (etapas L-0 a L-8). Si sus respuestas se refieren a una turbina con menos etapas, comience con L-0 y marque las etapas no aplicables con una "X". Si la turbina es más grande, sólo añada las celdas correspondientes a la derecha de L-8.

Conceptos principales

Un fallo de álabes es: "La situación en la que una inspección de la turbina (planificada o forzada por cualquier causa) revela que uno o más álabes han perdido la capacidad de realizar su función de una forma segura y confiable, y que es necesario un trabajo correctivo para poner la unidad en línea."

La frase "inspección de la turbina" incluye la inspección de los álabes rotatorios de la turbina durante cualquier mantenimiento programado o interrupción no programada, sin importar si la carcasa es extraída o no.

El término "influencia" en este contexto significa que uno o varios MD pueden causar directamente, servir como iniciadores o potenciadores, o en general, acelerar el proceso de evolución de otro mecanismo de daño dependiente (MD_i). Tal influencia conduce a

3.1. Clasifique la susceptibilidad de las filas de álabes a sufrir de daño por picaduras, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

3.2. Clasifique la susceptibilidad de las partes de los álabes a sufrir de daño por picaduras, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad.

Hoja	Cubierta	Alambre	Raíz

Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

3.3. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por picaduras cuando la turbina es inspeccionada?

Valor: _____%

4. Mecanismo de daño tipo erosión por goteo (Got_MD)

4.1. Clasifique la susceptibilidad de las filas de álabes a sufrir de daño por erosión por goteo, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

4.2. Clasifique la susceptibilidad de las partes de los álabes a sufrir de daño por erosión por goteo, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad.

Hoja	Cubierta	Alambre	Raíz

Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

4.3. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por erosión por goteo cuando la turbina es inspeccionada?

Valor: _____%

5. Mecanismo de daño por fricción (Fricc_MD)

5.1. Clasifique la susceptibilidad de las filas de álabes a sufrir de daño por fricción, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

5.2. Clasifique la susceptibilidad de las partes de los álabes a sufrir de daño por fricción, siendo 0 la imposibilidad de que la fila sufra el MD y 10 el mayor grado de susceptibilidad.

Hoja	Cubierta	Alambre	Raíz


Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

5.3. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por fricción cuando la turbina es inspeccionada?

Valor: _____%

6. Mecanismo de daño de agrietamiento asistido por corrosión bajo tensión (SCC_MD)

El agrietamiento por corrosión bajo estrés mecánico, en inglés *Stress Corrosion Cracking* (SCC) es modelado como dependiente de las picaduras y la fricción, los cuales pueden incrementar la probabilidad de ocurrencia de SCC. Sin embargo, el SCC puede manifestarse sin la presencia de los daños por picaduras y/o fricción, debido a factores no modelados explícitamente, agrupados es el nodo rojo. La siguiente figura representa el esquema de influencias.



Cuando SCC es observado en los álabes rotatorios durante una inspección de turbina, responda:

6.1. ¿Cuál es la probabilidad de influencia independiente de las picaduras sobre el SCC, descartando la influencia del daño por fricción y de otros posibles factores que influyen sobre el SCC?

Valor: _____%

6.2. ¿Cuál es la probabilidad de influencia independiente de la fricción sobre el SCC, descartando la influencia del daño por picaduras y de otros posibles factores que influyen sobre el SCC?

Valor: _____%

6.3. ¿Cuál es la probabilidad de influencia conjunta de las picaduras y la fricción sobre el SCC, descartando la influencia de otros posibles factores?

Valor: _____%

6.4. Clasifique la susceptibilidad de las filas de álabes a sufrir solamente de SCC (sin considerar las influencias de las picaduras y la fricción). Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

6.5. Clasifique la susceptibilidad de las partes de álabes a sufrir solamente de SCC (sin considerar las influencias de las picaduras y la fricción). Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

Hoja	Cubierta	Alambre	Raíz


Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

6.6. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por SCC sin la influencia de picaduras y fricción cuando la turbina es inspeccionada?

Valor: _____%

7. Mecanismo de daño por Fatiga mecánica (Fatiga_MD)

El daño por fatiga mecánica sin asistencia ambiental es modelado como dependiente de la erosión por goteo y la fricción, los cuales pueden incrementar la probabilidad de ocurrencia de la fatiga. Sin embargo, la fatiga puede manifestarse sin la presencia de los daños por erosión y/o fricción, debido a factores no modelados explícitamente, agrupados en el nodo rojo. La siguiente figura representa el esquema de influencias.



Cuando la fatiga mecánica es observada en los álabes rotatorios durante una inspección de turbina, responda:

7.1. ¿Cuál es la probabilidad de influencia independiente de la erosión por goteo sobre la fatiga, descartando la influencia del daño por fricción y de otros posibles factores que influyen sobre la fatiga?

Valor: _____%

7.2. ¿Cuál es la probabilidad de influencia independiente de la fricción sobre la fatiga, descartando la influencia del daño por la erosión por goteo y de otros posibles factores que influyen sobre la fatiga?

Valor: _____%

7.3. ¿Cuál es la probabilidad de influencia conjunta de la erosión por goteo y la fricción sobre la fatiga, descartando la influencia de otros posibles factores?

Valor: _____%

7.4. Clasifique la susceptibilidad de las filas de álabes a sufrir solamente fatiga mecánica (sin considerar las influencias de la erosión por goteo y la fricción). Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

7.5. Clasifique la susceptibilidad de las partes de álabes a sufrir solamente de fatiga mecánica (sin considerar las influencias de la erosión por goteo y la fricción).

Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

Hoja	Cubierta	Alambre	Raíz


Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

7.6. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por fatiga mecánica sin la influencia de la erosión por goteo y fricción cuando la turbina es inspeccionada?

Valor: _____%

8. Mecanismo de daño por corrosión fatiga (CF_MD)

El daño por corrosión fatiga (CF) es modelado como dependiente de las picaduras, el SCC y la fricción, los cuales pueden incrementar la probabilidad de ocurrencia de CF. Sin embargo, el CF puede manifestarse sin la presencia de los daños por picaduras, SCC y/o fricción, debido a factores no modelados explícitamente, agrupados es el nodo rojo. La siguiente figura representa el esquema de influencias.



Cuando la CF es observada en los álabes rotatorios durante una inspección de turbina, responda:

8.1. ¿Cuál es la probabilidad de influencia independiente del daño por picaduras sobre la CF, descartando la influencia del SCC la fricción y de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.2. ¿Cuál es la probabilidad de influencia independiente del SCC sobre la CF, descartando la influencia del daño por picaduras, fricción y de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.3. ¿Cuál es la probabilidad de influencia independiente de la fricción sobre la CF, descartando la influencia del daño por picaduras, SCC y de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.4. ¿Cuál es la probabilidad de influencia conjunta de las picaduras y el SCC sobre la CF, descartando la influencia del daño por fricción de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.5. ¿Cuál es la probabilidad de influencia conjunta de las picaduras y la fricción sobre la CF, descartando la influencia del daño por SCC y de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.6. ¿Cuál es la probabilidad de influencia conjunta del SCC y la fricción sobre la CF, descartando la influencia del daño por picaduras y de otros posibles factores que influyen sobre la CF?

Valor: _____%

8.7. Clasifique la susceptibilidad de las filas de álabes a sufrir solamente de CF (sin considerar las influencias de las picaduras, el SCC y la fricción). Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8

8.8. Clasifique la susceptibilidad de las partes de álabes a sufrir solamente de CF (sin considerar las influencias de las picaduras, el SCC y la fricción). Asigne 0 a la imposibilidad de que la fila sufra el MD y 10 al mayor grado de susceptibilidad. Marque "X" si la fila no existe físicamente.

Hoja	Cubierta	Alambre	Raíz

Nota: Al menos un 10 es requerido en cada tabla. El uso del 0 es opcional. Los valores pueden repetirse dentro de la misma tabla y en ambas tablas.

8.9. Para la(s) combinación(es) de ubicación que eligió como más susceptible(s) (es decir, 10 en ambas tablas), ¿cuál es la proporción de veces que ha observado o espera observar el daño por CF sin la influencia de las picaduras, SCC y fricción cuando la turbina es inspeccionada?

Valor: _____%

9. Partes de los álabes en las filas (Álabe_PP)

Algunas partes de los álabes de la Figura 27 pudieran no estar presentes en cada fila. Indique la presencia de las siguientes partes con un "1" y su ausencia con un "0". Indique las filas que no existen con una "X" o añada columnas según necesite.

	L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8
Cubierta									
Alambre									

10. Fallo de la turbina (MF-Turb)

¿Cuán frecuentes son encontrados los modos de fallo por corrosión, agrietamiento o fractura y erosión en las paradas o inspecciones programadas *versus* forzadas? Proporcione sus estimados en por ciento.

	Corrosión	Agrietamiento/fractura	Erosión
Programado			
Forzado			

Nota: las columnas deben sumar 100%.

Anexo B: Cálculo de las tablas de probabilidad condicional a partir de la encuesta

Tenga en cuenta los siguientes puntos antes de proceder con los incisos para calcular las tablas de probabilidad condicional (TPC):

- Todos los valores deben ser convertidos a decimales en escala 0 a 1 para ser introducidos en las ecuaciones de las instrucciones subsiguientes, excepto los que se encuentran dentro de las tablas.
- Con estas instrucciones se calculan las probabilidades de los estados presente (pres) de los mecanismos de daño. La probabilidad de los estados ausente (aus) son el complemento.
- En dependencia de la cantidad de filas de álabes, elimine o añada las filas pertinentes en los nodos Alabe_PP y Alabe_Fila. Luego normalice sus tablas de probabilidad condicional antes de introducir los datos calculados mediante estas instrucciones.

Instrucciones:

- El valor recopilado en 2.1 corresponde a la celda pres-pres de la TPC de Corr_MF. La celda aus-aus posee el valor de 1.
- El valor recopilado en 2.2 corresponde a la celda pres-pres de la TPC de Eros_MF. La celda aus-aus posee el valor de 1
- La TPC del nodo Ag/Fr_ MF es un OR determinista, por lo que no se necesita el juicio de expertos.
- Los estados presentes del nodo Pic_MD se obtienen de la siguiente manera:
 - Multiplique valor a valor la tabla de 3.1 por la tabla de 3.2 y divida por 100 para obtener la matriz de susceptibilidad (MS) representada en la siguiente tabla.

A.part/fila	L-0	L-1	L-2	L-3	L-4	L-5	L-6	L-7	L-8
Hoja	L-0*Hoja/100
Cubierta	L-0*Cubierta/100
Alambre	L-0*Alambre/100
Raíz	L-0*Raíz/100	L-8*Raíz/100

- La probabilidad de los estados presente de su TPC, se calculan como $P.leak_{j,k} = MS * (valor\ de\ la\ pregunta\ 3.3)$. La probabilidad de los estados ausentes es el complemento.
- Reemplace por 0 todas las combinaciones inexistentes según la información de la pregunta 9.

- e) La TPC de Got_MD es obtenida como en d) pero usando la tabla de 4.1, la tabla de 4.2 y el valor de 4.3.
- f) La TPC de Fricc_MD es obtenida como en d) pero usando la tabla de 5.1, la tabla de 5.2 y el valor de 5.3.
- g) La TPC de SCC_MD es construida a partir de las siguientes sub-TPC:
- Calcule su $P.leak_{j,k}$ como en d) pero usando la tabla de 6.4, la tabla de 6.5 y el valor de 6.6. La sub-TPC resultante corresponde a la combinación $P(SCC_MD = pres|Pic_MD = aus, Fricc_MD = aus)$
 - La combinación $P(SCC_MD = pres|Pic_MD = pres, Fricc_MD = aus) = P.leak_{j,k} * (valor de pregunta 6.1)$
 - La combinación $P(SCC_MD = pres|Pic_MD = aus, Fricc_MD = pres) = P.leak_{j,k} * (valor de pregunta 6.2)$
 - La combinación $P(SCC_MD = pres|Pic_DM = pres, Fricc_MD = pres) = P.leak_{j,k} * (valor pregunta 6.3)$
 - Reemplace por 0 todas las combinaciones inexistentes según la información de la pregunta 9 y combine todas las sub-TPC en el formato deseado para conformar la TPC.
- h) La TPC de Fatiga_MD es construida a partir de las siguientes sub-TPC:
- Calcule su $P.leak_{j,k}$ como en d) pero usando la tabla de 7.4, la tabla de 7.5 y el valor de 7.6. La sub-TPC resultante corresponde a la combinación $P(Fatiga_MD = pres|Got_MD = aus, Fricc_MD = aus)$
 - La combinación $P(Fatiga_MD = pres|Got_MD = pres, Fricc_MD = aus) = P.leak_{j,k} * (valor pregunta 7.1)$
 - La combinación $P(Fatiga_MD = pres|Got_MD = aus, Fricc_MD = pres) = P.leak_{j,k} * (valor pregunta 7.2)$
 - La combinación $P(Fatiga_MD = pres|Got_MD = pres, Fricc_MD = pres) = P.leak_{j,k} * (valor pregunta 7.3)$
 - Reemplace por 0 todas las combinaciones inexistentes según la información de la pregunta 9 y combine todas las sub-TPC en el formato deseado para conformar la TPC.
- i) La TPC de CF_MD es construida a partir de las siguientes sub-TPC:
- Calcule su $P.leak_{j,k}$ como en d) pero usando la tabla de 8.7, la tabla de 8.8 y el valor de 8.9. La sub-TPC resultante corresponde a la combinación $P(CF_MD = pres|Pic_MD = aus, SCC_MD = aus, Fricc_MD = aus)$

Nota: para los restantes guiones de este inciso, asegúrese de cumplir con la condición A del paso 7 de la sección 4.4.2 de esta tesis.

- La combinación $P(CF_MD = pres|Pic_MD = pres, SCC_MD = aus, Fricc_MD = aus) = P.leak_{j,k} * (valor pregunta 8.1)$

- La combinación

$$P(CF_MD = pres|Pic_MD = aus, SCC_MD = pres, Fricc_MD = aus) = P.leak_{j,k} * (valor\ pregunta\ 8.2)$$
- La combinación

$$P(CF_MD = pres|Pic_MD = aus, SCC_MD = aus, Fricc_MD = pres) = P.leak_{j,k} * (valor\ pregunta\ 8.3)$$
- La combinación

$$P(CF_MD = pres|Pic_MD = pres, SCC_MD = pres, Fricc_MD = aus) = P.leak_{j,k} * (valor\ pregunta\ 8.4)$$
- La combinación

$$P(CF_MD = pres|Pic_MD = pres, SCC_MD = aus, Fricc_MD = pres) = P.leak_{j,k} * (valor\ pregunta\ 8.5)$$
- La combinación

$$P(CF_MD = pres|Pic_MD = aus, SCC_MD = pres, Fricc_MD = pres) = P.leak_{j,k} * (valor\ pregunta\ 8.6)$$
- Calcule $P^{ENOR}(Pic_MD = pres, SCC_MD = pres, Fricc_MD = pres) = 1 - \frac{(1-V_{8.4})(1-V_{8.5})(1-V_{8.6})}{(1-V_{8.1})(1-V_{8.2})(1-V_{8.3})}$

Donde V_x representa el valor dado en la pregunta x (p.ej., $V_{8.6}$ es el valor dado a la pregunta 8.6).

- La combinación

$$P(CF_MD = pres|Pic_MD = pres, SCC_MD = pres, Fricc_MD = pres) = P.leak_{j,k} * P^{ERNOR}(Pic_MD = pres, SCC_MD = pres, Fricc_MD = pres)$$
- Reemplace por 0 todas las combinaciones inexistentes según la información de la pregunta 9 y combine todas las sub-TPC en el formato deseado para conformar la TPC.
- j) La TPC del nodo Alabe_Fila es una normal respecto a la cantidad de estados, coincidentes con la cantidad de filas de la turbina
- k) La TPC del nodo Alabe_PP es una normal, con valores iguales a cero para las partes de los álabes que no existen en algunas filas (información de la pregunta 9).
- l) El nodo MF-Turb es un *Noisy* OR que utiliza los valores de la tabla de la pregunta 10 para los estados “forzado” y “programado”. El estado “no-MF” es cero, excepto para cuando Eros_MF, Ag/Fr_MF y Corr_MF están ausentes simultáneamente, en cuyo caso su valor es 1.