



DETECCIÓN Y AUTODIAGNÓSTICO DE FALLAS EN SISTEMAS PRODUCTIVOS

RICARDO MORALES DOMÍNGUEZ

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
PROGRAMA DE POSGRADOS DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA
SANTIAGO DE CALI
2014**



DETECCIÓN Y AUTODIAGNÓSTICO DE FALLAS EN SISTEMAS PRODUCTIVOS

RICARDO MORALES DOMÍNGUEZ

Disertación presentada al Programa de Posgrados En Ingeniería Eléctrica y Electrónica, de la Universidad del Valle para optar al título de Maestría en Ingeniería con Énfasis en Automática

DIRECTOR

ING. JOSÉ ISIDRO GARCIA MELO M.SC., PH. D

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
PROGRAMA DE POSGRADOS DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA
SANTIAGO DE CALI
2014**

Nota de aceptación.

Aprobado por el comité del Programa de Posgrados de Ingeniería Eléctrica y Electrónica de la Universidad del Valle, en cumplimiento de los requisitos exigidos para optar al título de Maestría en Ingeniería con Énfasis en automática.

JOSÉ ISIDRO GARCÍA MELO
Director del Proyecto

Jurado

Jurado

Santiago de Cali, Noviembre 10 de 2014

AGRADECIMIENTOS

En primer lugar, quiero agradecer a Dios por ser una infinita fuente de luz, paciencia y sabiduría para llevar a cabo este trabajo.

A mi orientador, el profesor José Isidro García, quién desde mi pregrado hasta esta maestría, ha estado presente, aportando en mi formación personal y profesional, confió en mi este proyecto e hizo posible el desarrollo del mismo de principio a fin.

A mis compañeros Felipe Mejía Donneys, Gustavo Rojas y Jesús Filander Caratar, quiénes hicieron valiosos aportes a mi proyecto desde sus respectivos proyectos de investigación.

A mi madre, por su infinito amor y apoyo en todos los proyectos que he emprendido en mi vida.

CONTENIDO

1. INTRODUCCIÓN	1
1.1. Objetivo General	4
1.2. Objetivos específicos	4
2. MARCO CONCEPTUAL	5
2.1. Detección y diagnóstico de fallas. Estado del arte	5
2.2. Fundamentación Teórica.....	15
2.2.1. Sistemas Productivos	15
2.2.2. Redes Bayesianas.....	18
2.3. Resumen del capítulo.....	21
3. PROPUESTA.....	23
3.1. Desarrollo de un sistema de diagnóstico con redes bayesianas	23
3.1.1. Delimitar el caso de estudio	26
3.1.2. Definir el sistema observador	27
3.1.3. Listar las fallas conocidas	28
3.1.4. Relacionar fallas y síntomas	30
3.1.5. Definir la topología.....	33
3.1.6. Definir probabilidades	33
3.2. Desarrollo del sistema de diagnóstico cuando hay fallas con síntomas idénticos.	44
3.2.1. Delimitar el caso de estudio	45
3.2.2. Definir el sistema observador	45
3.2.3. Listar las fallas conocidas	46
3.2.4. Relacionar fallas y síntomas	46
3.2.5. Identificar fallas con síntomas idénticos.....	47
3.2.6. Agrupar fallas con síntomas idénticos	47
3.2.7. Definir la topología.....	48
3.2.8. Definir probabilidades	49
3.3. Sistema de Diagnóstico. Tabla de diagnóstico	52
3.4. Validación del sistema de Diagnóstico	53

3.5.	Afinación del sistema de diagnóstico	54
3.6.	Resumen del capítulo	55
4.	CASOS DE ESTUDIO.....	56
4.1.	Caso estudio 1. Preparación de crema desodorante.....	56
4.1.1.	Caso estudio 1. Delimitar el caso de estudio	58
4.1.2.	Caso estudio 1. Definir el sistema observador	59
4.1.3.	Caso estudio 1. Listar las fallas conocidas	59
4.1.4.	Caso estudio 1. Relacionar fallas y síntomas	60
4.1.5.	Caso estudio 1. Definir la topología	60
4.1.6.	Caso estudio 1. Definir probabilidades	61
4.1.7.	Caso estudio 1. Sistema de Diagnóstico. Tabla de diagnóstico	64
4.1.8.	Caso estudio 1. Validación del diagnóstico	64
4.2.	Modificación caso estudio 1. Preparación de crema desodorante.	68
4.2.1.	Caso estudio 1. Definir topología considerando la agrupación de nodos	69
4.2.2.	Caso estudio 1. Definir probabilidades considerando la agrupación de nodos	69
4.2.3.	Caso estudio 1. Tabla de diagnóstico y validación.....	71
4.3.	Caso estudio 2. Proceso de potabilización de agua	72
4.3.1.	Caso estudio 2. Delimitar el caso de estudio	75
4.3.2.	Caso estudio 2. Definir el sistema observador	76
4.3.3.	Caso estudio 2. Listar las fallas conocidas	78
4.3.4.	Caso estudio 2. Relacionar fallas y síntomas	78
4.3.5.	Identificar fallas con síntomas idénticos.....	79
4.3.6.	Caso estudio 2. Agrupar fallas con síntomas idénticos	80
4.3.7.	Caso estudio 2. Definir la topología	80
4.3.8.	Caso estudio 2. Definir probabilidades	81
4.3.9.	Caso estudio 2. Sistema de Diagnóstico. Tabla de diagnóstico.	84
4.3.10.	Caso estudio 2. Validación del diagnóstico.....	85
5.	CONCLUSIONES	90
5.1.	Resultados principales	90

5.2. Trabajos futuros	92
6. Bibliografía.....	94

LISTA DE FIGURAS

Figura 2-1. Clasificación de algoritmos de Diagnóstico. [1]	6
Figura 2-2. Visión general del sistema productivo.	17
Figura 2-3. Red Bayesiana simple - Grafico aciclico dirigido (Directed Aciclyc Graphic - DAG) [20]	19
Figura 3-1. Diagrama General del Sistema Propuesto	23
Figura 3-2. Pasos para el diseño del sistema de diagnóstico	25
Figura 3-3. Diagrama General Observador	27
Figura 3-4. Forma General Red Bayesiana tipo Naive	33
Figura 3-5. Ejemplo patrón de síntomas ante una falla	34
Figura 3-6. Ejemplo falla con síntomas idénticos	45
Figura 3-7. Ejemplo síntomas idénticos. Topología de red modificada	48
Figura 4-1. Diagrama proceso preparación de crema desodorante	57
Figura 4-2. Sistema de pre-calentador-Reactor en cascada.....	57
Figura 4-3. Caso de estudio 1. Red Naive Bayes de diagnóstico.	60
Figura 4-4. Caso estudio 1. Gráficos de diagnóstico de la red ante cada falla	66
Figura 4-5. Caso estudio 1. Diagnóstico de la red ante cada falla, con probabilidades a priori modificadas.	68
Figura 4-6. Caso estudio 1. Topología de red con agrupación de nodos.....	69
Figura 4-7. Caso estudio 2. Esquema general del proceso[35]	73
Figura 4-8. Caso estudio 2. Diagrama de bloques general PTAP Puerto Mallarino	74
Figura 4-9. Caso estudio 2. Bloque Observador.....	77
Figura 4-10. Caso de estudio 2. Red de diagnóstico	80
Figura 4-11. Caso estudio 2. Gráficos de diagnóstico de la red ante cada falla ..	89

LISTA DE TABLAS

Tabla 2-1. Escala de probabilidad	8
Tabla 2-2. Resumen aplicaciones detección y diagnóstico de fallas	14
Tabla 3-1. Plantilla general para la descripción de las variables del sistema.....	26
Tabla 3-2. Plantilla general del vector de síntomas	28
Tabla 3-3. Plantilla general del listado de fallas y los síntomas que afectan.....	29
Tabla 3-4. Plantilla general de los estados normales de los síntomas ante cada falla.	31
Tabla 3-5. Plantilla general de estados normales de los síntomas ante cada falla, con valores de ejemplo.	31
Tabla 3-6. Ejemplo probabilidades a priori a partir de registros históricos	35
Tabla 3-7. Ejemplo probabilidades a priori a partir de encuesta a los expertos	35
Tabla 3-8. Ejemplo probabilidades a priori distribuidas de forma uniforme	36
Tabla 3-9. Plantilla general para las probabilidades condicionadas de los síntomas ante la combinación de fallas	37
Tabla 3-10. Plantilla general de probabilidades condicionadas de los síntomas considerando una sola falla presente	38
Tabla 3-11. Valores del ejemplo para las probabilidades condicionadas.....	40
Tabla 3-12. Estados normales de los síntomas ante las fallas, indicados por los expertos	41
Tabla 3-13. Ejemplo probabilidades condicionadas a partir de estados normales en falla	44
Tabla 3-14. Ejemplo síntomas idénticos. Variables del sistema	45
Tabla 3-15. Ejemplo síntomas idénticos. Vector de síntomas	46
Tabla 3-16. Ejemplo síntomas idénticos. Tabla de fallas	46
Tabla 3-17. Ejemplo síntomas idénticos. Estados normales de los síntomas ante las fallas conocidas	46
Tabla 3-18. Plantilla general para el listado de nodos de agrupación	47
Tabla 3-19. Ejemplo síntomas idénticos. Listado de nodos de agrupación.....	48
Tabla 3-20. Ejemplo síntomas idénticos. Probabilidades a priori.....	49
Tabla 3-21. Ejemplo síntomas idénticos. Probabilidades condicionadas del nodo grupo G1.....	50
Tabla 3-22. Ejemplo síntomas idénticos. Probabilidades condicionadas de los síntomas	51
Tabla 3-23. Plantilla general diagnóstico generado	53
Tabla 3-24. Ejemplo de diagnóstico generado por el sistema	53
Tabla 4-1. Caso estudio 1. Variables del sistema.....	58
Tabla 4-2. Caso estudio 1. Tabla con vectores de síntomas	59
Tabla 4-3. Caso estudio 1. Listado de fallas conocidas	59
Tabla 4-4. Caso estudio 1. Estados normales de los síntomas ante las fallas.....	60

Tabla 4-5. Caso estudio 1. Probabilidades a priori	61
Tabla 4-6. Caso estudio 1. Tablas de probabilidad condicionada síntomas S1TI1, S2LI2 y S3FI2	61
Tabla 4-7. Caso estudio 1. Tablas de probabilidad condicionada síntomas S4, S5 y S6.	62
Tabla 4-8. Caso estudio 1. Tabla completa de probabilidades condicionadas.....	63
Tabla 4-9. Caso estudio 1. Probabilidades condicionadas a partir de estados normales en falla.....	63
Tabla 4-10. Caso estudio 1. Tabla de diagnóstico.....	64
Tabla 4-11. Caso estudio 1. Tabla de Diagnóstico para la falla F3.....	65
Tabla 4-12. Caso estudio 1. Diagnostico ante cada falla con probabilidades a priori modificadas.....	65
Tabla 4-13. Caso estudio 1. Probabilidades a priori modificadas	67
Tabla 4-14. Caso estudio 1. Diagnóstico con probabilidades a priori modificadas.	67
Tabla 4-15. Caso estudio 1. Probabilidades condicionadas del nodo grupo G1 ...	70
Tabla 4-16. Caso estudio 1. Tablas de probabilidad condicionada teniendo en cuenta la agrupación de fallas.....	70
Tabla 4-17. Caso estudio 1. Tabla completa de probabilidades considerando la agrupación de fallas	71
Tabla 4-18. Caso estudio 2. Variables del sistema.....	76
Tabla 4-19. Caso estudio 2. Tabla con vectores de síntomas	77
Tabla 4-20.Caso estudio 2. Listado de fallas conocidas	78
Tabla 4-21. Caso estudio 2. Estados normales de los síntomas ante las fallas....	79
Tabla 4-22. Caso estudio 2. Nodos de agrupación identificados	80
Tabla 4-23. Caso estudio 2. Probabilidades a priori	81
Tabla 4-24.Caso estudio 2. Probabilidades condicionadas del nodo grupo G1	82
Tabla 4-25.Caso estudio 2. Probabilidades condicionadas del nodo grupo G2	82
Tabla 4-26. Caso estudio 2. Probabilidades condicionadas a partir de estados normales en falla.....	83
Tabla 4-27.Caso estudio 2. Tabla de probabilidades condicionadas de los síntomas	83
Tabla 4-28. Caso estudio 2. Tabla de diagnóstico.....	84
Tabla 4-29.Caso estudio 2. Tabla de diagnóstico para la falla F2	86
Tabla 4-30.Caso estudio 2. Tabla de diagnóstico para la falla F4	86
Tabla 4-31. Caso estudio 2.Diagnóstico de la red ante cada falla	88

RESUMEN

En la actualidad, dadas las dinámicas de nuestra sociedad en el consumo de bienes y servicios, los sistemas productivos enfrentan grandes retos en términos de calidad, costos y eficiencia en el uso de los recursos para producirlos. En ese sentido, se hace necesario buscar mecanismos que permitan incrementar la confiabilidad de los sistemas de producción, reducir los tiempos de respuesta ante las fallas en los mismos, y mitigar los impactos que éstas fallas tienen sobre la calidad y el costo del producto/servicio.

Un sistema productivo es un conjunto de procesos que generan transformaciones en determinadas materias primas, para obtener un bien (producto) o servicio. Una falla en un sistema productivo, es el desvío de por lo menos una de las propiedades del sistema, que lleva el mismo a un estado no especificado, de comportamiento anormal o no proyectado. Una forma de reducir los impactos negativos que tienen las fallas sobre los procesos productivos, es que ante un evento de falla, se genere una respuesta rápida y adecuada que lleve el sistema productivo a un estado seguro, y la identificación veraz y oportuna de las fallas es el primer paso para lograrlo.

En ese sentido, en este trabajo se propone generar sistemas de diagnóstico basados en redes Bayesianas, mediante los cuales se pueda hacer una evaluación del estado del sistema productivo y arrojar un diagnóstico que permita hacer la identificación de una falla. Principalmente, en el trabajo se buscó obtener un procedimiento genérico para hacer el diseño del sistema de diagnóstico y fue puesto a prueba en dos casos de estudio particulares.

1. INTRODUCCIÓN

En los últimos tiempos, debido al continuo y rápido incremento en la complejidad de los productos y procesos de producción, las organizaciones han tenido que ajustar sus procesos productivos, para sobrevivir y responder a las exigentes demandas de un mercado cada vez más competitivo [1]. La necesidad de incluir nuevos productos de manera eficaz, con ciclos de vida más cortos, menores precios e igual o mejor calidad, ha llevado a las empresas a idear nuevas estrategias de producción, enfocándose en aspectos como costos, calidad, plazos de entrega, innovación y flexibilidad. En [2] estos focos estratégicos se definen de la siguiente manera:

- Costos. Es la capacidad para producir los bienes o servicios, manteniendo los precios bajos. Una regla general es que los productos estandarizados tienen a tener menores costos de producción.
- Calidad. Es la capacidad de mantener a los clientes satisfechos con el producto producido.
- Tiempo. Comprende dos posibilidades básicas: (a) asegurar la calidad a los clientes en el menor tiempo posible; y (b) atender a los clientes dentro de una franja de tiempo con la menor variación posible.
- Flexibilidad. Es la capacidad para responder a cambios en el mercado de manera rápida y eficaz.
- Innovación. Es la capacidad de atender a los clientes siempre con productos diferenciados y con características sin precedentes.

Tales exigencias han motivado avances en los sistemas productivos, encaminados a lograr la realización de ciertas tareas de forma autónoma con la ayuda de sistemas computarizados. En [3] se hace una breve reseña histórica de la evolución del control de procesos en la que se menciona que hasta hace algunos años. Donde, antes del procesamiento computacional, los ingenieros observaban los instrumentos y manualmente regulaban el comportamiento del proceso mediante mecanismos como la apertura y cierre de válvulas, encendido y apagado de motores, etc. Luego el control manual fue remplazado por controladores regulatorios mecánicos y neumáticos, que posteriormente se tornaron en control regulatorio basado en elementos electrónicos (controladores de bucla simple). Durante los años 60's los computadores empezaron a tener más relevancia en las buclas de control y después de la introducción de los primeros microprocesadores (como el Intel 8080) en el mercado, los sistemas de control empezaron a ser dominados por elementos como los DCS (Distributed Control System) y los PLC.

Actualmente, la automatización de los procesos productivos se encuentra en casi todos los niveles de la industria. De estos ambientes de producción automatizado, la mayoría se enfocan en la producción en masa, especialmente aquellos que se encuentran altamente automatizados [1]. Sin embargo, en [1] también se menciona que debido al creciente interés de los consumidores por acceder a una gran variedad de productos, la modularidad y flexibilidad de los sistemas de producción ha ganado gran importancia.

Lo anterior ha llevado a que los procesos productivos sean cada vez más complejos y menos dependientes de operadores humanos en cuanto a las tareas de producción. Sin embargo, una importante tarea en el manejo de los procesos, sigue teniendo una fuerte dependencia de operadores humanos: responder ante eventos anormales en la planta [4] que orientan el sistema a estados no especificados, donde una detección temprana de fallas y/o un adecuado diagnóstico de la causa (o causas) de las mismas, son fundamentales para tomar decisiones de control que lleven la planta a un estado seguro de operación o parada. No obstante, dado el tamaño y complejidad de las plantas modernas, con cientos de variables para monitorear, hace difícil un adecuado diagnóstico por parte de los operarios, lo que puede generar errores en las decisiones tomadas, llevando la planta a condiciones de operación incluso peores que la producida por la falla inicial [5].

Las fallas, o estados no especificados, son estados que deben evitarse ya que comprometen el desempeño global de un sistema [6]. En [5] se mencionan diferentes estadísticas que dan cuenta del impacto económico que pueden derivarse de un pobre manejo de los eventos de fallas: pérdidas por 20 billones de dólares al año, solamente en la industria farmacéutica de los Estados Unidos, y cerca de 27 billones de dólares en la economía Británica, son apenas un par de ejemplos que esbozan la dimensión del problema. Además, accidentes industriales como el ocurrido en la planta de pesticidas Union Carbide (Bhopal, India - 1984), o el incidente de la planta petrolera Piper Alpha (propiedad de Occidental Petroleum – California, 1988), mencionados en [7], así como el reciente incidente en la refinería venezolana de Amuay (Agosto de 2012), con fuertes impactos económicos y ambientales, además de las pérdidas humanas, ahondan aún más la necesidad de proponer soluciones que mejoren la seguridad de los sistemas productivos.

Es así como se ha incentivado un creciente interés, tanto a nivel industrial como académico, en el desarrollo de sistemas inteligentes de control que puedan proveer asistencia para las tareas de supervisión (supervisory control), en las que la detección y diagnóstico de las fallas, es un primer paso importante en el Manejo de Eventos Anormales (Abnormal Event Management – AEM)[7]. Alrededor del tema de la seguridad en los procesos industriales, existen diferentes líneas de investigación en las que se pueden identificar algunos términos como:

- HAZOP. (Hazard Analysis and Operation). Es una técnica de análisis de seguridad para identificar posibles variaciones del comportamiento

esperado de la planta-proceso y resaltar las consecuencias de las dificultades operacionales. [8]

- PHA. (Preliminary Hazard Analysis)[9] . Se usa en las etapas de diseño del sistema de producción. Ayuda a identificar los elementos peligrosos, internos o externos al sistema en estudio. Estos elementos peligrosos que se identifican, son estudiados para saber si podrían llevar a un incidente o situación potencialmente dañina. Está orientado a prever, más que a corregir.
- AEM. (Abnormal Event Management)[4]. Consiste en el conjunto de operaciones necesarias para llevar la planta-proceso, a un estado de control/parada cuando se presenta algún estado no especificado.
- SDG (Signed Digraph) [10]. Sistema de diagnóstico basado en un modelo gráfico del proceso.

Existen varias otras aproximaciones encaminadas a garantizar la seguridad y confiabilidad en los sistemas productivos, ya sea desde las etapas de diseño del mismo, o durante la operación y en tiempo real. Para este trabajo de investigación, se evaluaron específicamente sistemas de detección y diagnóstico de fallas cuya fundamentación es la teoría de Bayes, más concretamente, la teoría de redes Bayesianas. El trabajo se enfocó en identificar los elementos comunes entre distintas aplicaciones con redes Bayesianas y consolidar un procedimiento general para el diseño de sistemas de diagnóstico. Durante el desarrollo se pudo evidenciar la complejidad en este tipo de sistemas, que normalmente está ligada a la complejidad del sistema productivo bajo estudio. En ese sentido se propuso dividir el sistema en un bloque de detección de fallas y un bloque de diagnóstico de fallas, logrando tener un procedimiento genérico para el diseño del bloque de diagnóstico y dejando la complejidad de la planta en el bloque de detección.

1.1. Objetivo General

El objetivo general del proyecto es *concebir y plantear un procedimiento para diseño de mecanismos de supervisión de sistemas productivos, basados en redes Bayesianas, que permitan detectar fallas e inferir de forma autónoma, la causa probable de las mismas.*

Detrás de este objetivo, lo que se persigue es monitorear la integridad del sistema productivo y de cada uno de sus componentes, para garantizar que se encuentra siempre dentro de los parámetros normales de operación.

El procedimiento propuesto considera independientes la tarea de detección de una falla y la tarea de diagnóstico de la misma. El enfoque de las redes Bayesianas está orientado principalmente al problema de diagnóstico, mientras que la tarea de detección se deja abierta para ser implementada con diferentes métodos.

1.2. Objetivos específicos

- Estudiar los aspectos generales de sistemas productivos, para determinar sus características principales y establecer una clasificación de los mismos.
- Estudiar las características de las redes Bayesianas, y determinar el tipo de información de entrada que se requiere, para poder cuantificar relaciones de causa-efecto en un sistema productivo.
- Plantear un procedimiento de diseño de un sistema de supervisión, basado en redes Bayesianas, que permita la detección y el diagnóstico de fallas.
- Diseñar los experimentos que permitan obtener la información de entrada para el sistema de supervisión, de acuerdo a los requerimientos establecidos.
- Obtener la información de entrada para el sistema de supervisión, a partir de los experimentos establecidos.
- Implementar y simular el mecanismo de supervisión del sistema productivo.
- Validación y ajustes del sistema de supervisión obtenido, mediante datos experimentales tomados directamente en el sistema productivo.

2. MARCO CONCEPTUAL

En este capítulo se presenta una revisión bibliográfica realizada en torno a la detección y diagnóstico de fallas en sistemas productivos. Se presenta inicialmente un estado del arte en métodos para detección y diagnóstico de fallas para distintos sistemas, haciendo especial énfasis en aquellas aplicaciones donde se utiliza el concepto de inferencia Bayesiana a través de redes. El objetivo de esta revisión es identificar elementos comunes en las diferentes aplicaciones de diagnóstico de fallas. Se presenta además la fundamentación teórica necesaria para abordar el problema de detección y diagnóstico de fallas en sistemas productivos. En ese sentido, se hace una presentación de lo que son los sistemas productivos, resaltando las características relevantes de éstos para el proceso de diagnóstico, y se presentan los fundamentos teóricos de las redes Bayesianas.

2.1. Detección y diagnóstico de fallas. Estado del arte

Existen diferentes técnicas para la detección y diagnóstico de fallas, aplicadas a diferentes sistemas, ya sean productivos de manufactura o servicios, plantas y procesos industriales. El objetivo de este capítulo es presentar una revisión descriptiva de algunas técnicas para la detección y diagnóstico de fallas desarrolladas alrededor de la teoría de redes Bayesianas como método de inferencia. Para ello se resumen algunas de las aplicaciones encontradas cuya publicación se haya realizado en los últimos cinco años (2008-2014).

En el campo de la detección de fallas existen diversas investigaciones en las que se proponen diferentes soluciones tanto a la tarea de detección de la falla (detección de un comportamiento anormal) como en la clasificación de la misma (diagnóstico – tipo de falla). En [5], [11] y [12] se hace una revisión y clasificación de los diferentes métodos para detección y diagnóstico de fallas hasta el año 2003. En la Figura 2-1 se resumen los algoritmos de clasificación revisados por los autores.




Figura 2-1. Clasificación de algoritmos de Diagnóstico. [1]

Se puede observar que los métodos están divididos en tres categorías generales: Métodos basados en modelos cuantitativos, métodos basados en modelos cualitativos y métodos basados en la historia del proceso, todos ellos partiendo de la premisa de que existe una base de conocimiento a priori de las características cuantitativas, cualitativas o históricas del proceso a supervisar. Los métodos basados en modelos cuantitativos requieren del conocimiento analítico del proceso, por lo que generalmente su aplicación es limitada a sistemas lineales, invariantes y con disturbios cuyos modelos son simplificados [5]. Por otro lado, los métodos basados en modelos cualitativos no requieren de modelos matemáticos exactos, ya que pueden estimar el comportamiento general del proceso partiendo de información parcial, sin embargo, su gran desventaja es la generación de soluciones espurias [11]. Los métodos basados en la historia del proceso, requieren de la información histórica del mismo, a partir de la cual se extraen sus características ("feature extraction"), usando técnicas como sistemas expertos, clasificadores por redes neuronales, análisis de componentes principales o clasificadores estadísticos de patrones [12]. A nivel industrial, este tipo de sistemas de diagnóstico ha tenido una mayor difusión debido a su relativa facilidad de implementación y que no requieren modelos matemáticos exhaustivos [12].

Específicamente, alrededor de la teoría de Bayes, existen diferentes metodologías que buscan determinar, a través de probabilidad, la presencia de fallas y el tipo de las mismas. En [13] por ejemplo, se presenta una metodología para detección y

diagnóstico de fallas en procesos multivariados, donde se construyen sistemas de monitoreo del proceso partiendo de datos observados en el mismo. La metodología define unas hipótesis que representan estados de comportamiento normal, anormal, fallas en las entradas y fallas en las salidas. La teoría de Bayes se aplica para calcular la probabilidad de que un estado de las entradas y salidas del proceso, en un instante de tiempo, tenga relación con alguna de las hipótesis previamente establecidas. Esta técnica es aplicada para evaluar el comportamiento del vuelo de una aeronave. Un método similar es propuesto en [14], donde una serie de monitores evalúan la probabilidad de que un estado de falla sea producido por alguna hipótesis preestablecida, en este caso la aplicación se hace sobre sistemas informáticos. En [15] se utiliza la teoría Bayesiana para determinar la prioridad de revisión de los subsistemas de un proceso ante la presencia de un comportamiento anormal, partiendo del historial de fallas y la frecuencia de ocurrencia de éstas, aplicado al sistema de propulsión de un buque. Pero los esfuerzos no se han quedado allí, en [16] se presenta una propuesta en la que los autores demuestran que algunos métodos estadísticos de clasificación, usados en el ámbito de la detección de fallas, como las cartas de control T2 y MEWMA, pueden implementarse usando redes Bayesianas. Para ello, demuestran que estas cartas de control pueden verse como aplicaciones de la técnica de análisis discriminante, que básicamente es una técnica estadística para clasificación supervisada, basada en la regla de Bayes, y dado que las redes Bayesianas calculan la inferencia basadas en esta misma regla, entonces las técnicas de análisis discriminante pueden implementarse con redes Bayesianas.

Si bien existen diferentes enfoques para la detección y diagnóstico de fallas, e incluso hay diversidad alrededor de aplicaciones usando la teoría Bayesiana, esta revisión se centra en investigaciones que utilizan el teorema de Bayes en topologías de red, cuyas publicaciones se hayan realizado en los últimos seis años (2008 – 2014), y se resumen a continuación algunas de las referencias encontradas.

En [6] se presenta un procedimiento para diagnóstico y tratamiento de fallas en sistemas productivos. Específicamente, la detección de fallas se hace mediante redes Bayesianas. El sistema de diagnóstico es construido utilizando fuentes de información acerca del proceso tales como manuales, pruebas de procedimientos y conocimiento de expertos humanos. Para la construcción de la red Bayesiana, se definen las fallas para las que el sistema de diagnóstico será diseñado, se escoge un conjunto de variables donde cada variable se asocia a una falla, y se establece la influencia que puede tener cada una de estas variables sobre un componente específico del sistema productivo. De esta manera se obtiene una topología de red donde se puede observar la relación entre las fallas definidas y

los componentes del sistema productivo. La relación cuantitativa entre los componentes de la red Bayesiana es obtenida de manera subjetiva, donde un experto define las ponderaciones de acuerdo a su base de conocimiento. Finalmente, el procesamiento de la información para llevar a cabo la inferencia es realizado utilizando el algoritmo de propagación de probabilidad en arboles de grupos (probability propagation in trees of clusters). Como ejemplo de aplicación, los autores presentan la detección de fallas en un sistema de entrada de material (MES – material entry system) a una línea de proceso de limpiado de metal (pickling), con resultados satisfactorios, notando que después de varias pruebas ante diferentes síntomas, el sistema de diagnóstico pudo identificar la falla.

En [17] se presenta un sistema experto universal para detección de fallas. Entre diferentes técnicas de inferencia evaluadas por los autores (como redes neuronales y teoría fuzzy, entre otros), se escogen las redes Bayesianas debido a la facilidad para observar en éstas la relación entre síntomas y causas, y la capacidad para manejar incertidumbres. Para la construcción del sistema de diagnóstico se usa igualmente la base de conocimiento de humanos expertos en las operaciones de mantenimiento de la maquinaria, y se resalta la importancia de incluir como fuente de información tanto a los expertos ingenieros como a los operadores de la planta. Esta base de conocimiento es representada como un conjunto de reglas condicionales (Ejemplo: *IF condicion1 THEN consecuencia [% Probabilidad]*), donde se establece una probabilidad para una consecuencia dada una condición específica. Se establece además que los síntomas se consideran independientes entre sí, al igual que las causas, por lo tanto si se tienen m síntomas independientes y n causas independientes, los expertos deben juzgar y ponderar $m*n$ parejas de síntoma/causa, para lo cual los autores proponen una tabla llamada “Cuestionario de Relación Causal” (Causal Relationship Questionnaire). La relación cuantitativa entre los componentes de la red, se establece utilizando una escala de probabilidad propuesta en [18] donde se asigna una ponderación numérica a una expresión verbal de probabilidad (Tabla 2-1).

Tabla 2-1. Escala de probabilidad

Expresión	Probabilidad
Seguro	100
Probable	85
Esperado	75
Cincuenta – Cincuenta	50
Incierto	25
Improbable	15
Imposible	0

Finalmente, el procesamiento de la información es realizado por medio de inferencia diagnóstica, aplicando el teorema de Bayes, para calcular la

probabilidad de los nodos hijos (causas) dada la ocurrencia de los nodos padres (síntomas). Como ejemplo de aplicación los autores presentan la detección de fallas en una fábrica de circuitos integrados (chipset Factory). En el artículo muestran las tablas de fallas y causas, así como la tabla del cuestionario de relación causal, la topología de la red obtenida y el procedimiento para el cálculo de la probabilidad usando el teorema de Bayes, concluyendo que los resultados de los diagnósticos son satisfactorios.

En [19] se presenta la detección de fallas en una planta de procesos químicos industriales, usando redes Bayesianas. Para la construcción del sistema de diagnóstico se asume la disponibilidad de modelos matemáticos precisos, o de datos dinámicos obtenidos directamente del proceso, suficientes y exactos para describir la relación entre las variables del mismo. Se definen inicialmente las variables esenciales de control y monitoreo, y para éstas se determinan los valores de estado estable así como los valores permisibles de desviación del punto de referencia (Set point). Para cada variable esencial se definen también los valores máximo y mínimo que comprenden el rango considerado normal para la variable en cuestión. Para la detección y diagnóstico de las fallas, se plantean dos pasos, en primer lugar una red Bayesiana se encarga de detectar la desviación del proceso de su estado normal de operación y una segunda red Bayesiana se encarga de identificar el tipo de falla. La estructura de las redes está compuesta de forma general por tres partes: capa de fallas, capa de reconocimiento de patrones y capa de variables medidas. El número de nodos en la red está ligado al número de estados requeridos para cubrir todo el rango de fluctuación en los valores de las variables especificadas. La relación cuantitativa entre los nodos de la red es definida utilizando la capacidad de aprendizaje de la misma, para lo cual se obtienen datos que representan el comportamiento del proceso tanto en modo normal, como en presencia de fallas conocidas, y se realiza el entrenamiento de las redes con esta información. En el artículo, los autores mencionan simulaciones de 25 horas para obtener los datos de entrenamiento, y de 48 horas para obtener los datos de testeo. Como ejemplo de aplicación, los autores utilizan un simulador de una planta química industrial, conocido como *Tennessee Eastman process (TEP)*, obteniendo un tiempo de detección de fallas menor a 180 segundos con una exactitud en el diagnóstico hasta del 90%. Sin embargo, el método impone restricciones en cuanto a que no debe haber fallas en los sensores, controladores ni actuadores, además de que se asume que no se presentan de manera simultánea fallas de diferentes tipos.

Los trabajos mencionados hasta ahora parten de la premisa de la existencia de una base de conocimiento del proceso o maquinaria a supervisar, a partir de la cual se construye la estructura de la red Bayesiana. La propuesta desarrollada en

[20] presenta un método diferente en el cual la estructura de la red es determinada a partir de un conjunto de datos obtenidos directamente de la planta bajo supervisión y no se requiere proporcionar ninguna base de conocimiento de expertos para la construcción de la red. Básicamente, se cuenta con un conjunto de datos que se procesan hasta obtener una estructura de red que mejor se acomode a estos datos. Este proceso es llevado a cabo utilizando el método *Particle Swarm Optimization (PSO)*, el cual se encarga de optimizar un problema tratando de mejorar iterativamente una solución candidata, utilizando una función de puntuación (scoring function). Este algoritmo toma como entrada los datos obtenidos de la planta, el espacio de búsqueda, que corresponde a un conjunto de posibles estructuras, y la función de puntuación. La estructura con la mejor puntuación es la escogida para formar la red Bayesiana. Una vez se construye la red utilizando el conjunto de datos de entrada, ésta puede ser utilizada para la predicción de fallas tomando como entradas nuevos conjuntos de datos medidos en la planta. Como ejemplo de aplicación, los autores muestran el funcionamiento de la metodología para la detección de fallas en motores de aeroplanos, con resultados satisfactorios. Cabe destacar sin embargo, que los algoritmos necesarios para hallar la estructura de red adecuada son computacionalmente costosos, ya que el número de estructuras a evaluar crece exponencialmente con el número de variables del sistema. Para su implementación, los autores aplican técnicas de computación paralela utilizando un clúster de computadores con 48 CPUs, lo cual podría limitar su aplicación.

Por otro lado, otra tendencia para la detección de fallas es presentada en [21]. El objetivo de los autores es mejorar la confiabilidad de la información proporcionada por un conjunto de sensores distribuidos que miden variables climatológicas, en el marco del programa *Atmospheric Radiation Measurement (ARM)*, operado por el departamento de energía de los Estados Unidos. El objetivo principal es determinar si una medida entregada por un sensor está dentro de los valores posibles de acuerdo a su historial y las medidas entregadas por los demás sensores de la red. Dadas las difíciles condiciones climatológicas de los sitios donde están ubicados los sensores, la tendencia de éstos a fallar o desviarse de su punto operacional por las mismas condiciones ambientales, las lejanas ubicaciones, y considerando la perspectiva de crecimiento en cuanto a cantidad de sensores instalados y el volumen de información a manejar, los autores argumentan que las técnicas tradicionales en las que se diseñan módulos de análisis individuales no son escalables. Su propuesta se centra en modelar esta red de sensores distribuidos, con una red Bayesiana Dinámica. La connotación de *dinámica* se da porque se incluye la variable *tiempo* en el cálculo de la inferencia de la red Bayesiana. Para el análisis temporal, la red Bayesiana Dinámica modela la evolución estocástica de un conjunto de variables en el tiempo. En una red

Bayesiana Dinámica, el tiempo es discreto y las distribuciones condicionales hacia las variables padre están dadas tanto para el tiempo actual como para momento pasados. Los arcos de la red Bayesiana Discreta, siempre van en una dirección tal que representan las dependencias causales entre los eventos presentes y futuros. Para la construcción de la red Bayesiana, utilizan una base de datos que contiene información de cerca de 15 años de mediciones de las variables climatológicas de interés. La dependencia condicional entre estas variables se obtiene calculando el coeficiente de correlación producto-momento de Pearson (*Pearson product-moment correlation coefficient – PMCC*) para cada par de variables en la fuente de información y escogiendo las que arrojan el mayor coeficiente de correlación. Además, este procedimiento se complementa con la información proporcionada por los científicos expertos en el tema, para tener un conjunto completo de dependencias condicionales. Obtenida la estructura de la red, se procede con la etapa de aprendizaje, para lo cual se usa el algoritmo *expectation-maximization (EM)* aplicado a los datos históricos de los sensores, con el cual se obtienen las tablas de probabilidad condicional para cada variable de la red Bayesiana. Para conseguir la característica dinámica y permitir el análisis temporal, la red Bayesiana se replica en tres instantes de tiempo diferentes, donde cada instante de tiempo representa un periodo igual al periodo de muestreo de la fuente de información a partir de la cual se construyó la red inicial. Se hace solo sobre tres instantes de tiempo para mantener una red Bayesiana Dinámica simplificada. Finalmente, para calcular la inferencia en la detección de fallas con la red Bayesiana Dinámica, utilizan el algoritmo Lauritzen-Spiegelhalter, que es un algoritmo para el cálculo exacto de inferencias con el que pretenden evitar la propagación de errores acumulativos. Una vez construida la red, ésta es alimentada con datos de observaciones reales. Cuando una nueva evidencia llega en el instante t , la evidencia para los instantes $t-2$ y $t-1$ se traslada a través de la red como una ventana deslizante. Este tipo de red es computacionalmente costosa y fácilmente consume grandes recursos de memoria, por lo que los autores restringen la detección de fallas para cubrir solo 21 mediciones consideradas críticas, además, para cada variable, limitan la dependencia condicional a cuatro variables padre en el mismo instante de tiempo, y cinco (cuatro padres y la variable misma) para el instante de tiempo anterior. Para validar el desarrollo, se presenta una herramienta visual donde se observa la evolución de los estados de las variables y la inferencia de las posibles fallas detectadas.

Una línea de investigación similar a la presentada anteriormente se aborda en [22], donde se propone la construcción de redes Bayesianas con estructura variable en el tiempo. Los autores sostienen que en lugar de ver las redes como entidades invariantes, éstas pueden considerarse como meta-estructuras que

modifican dinámicamente sus conexiones y la relación cuantitativa entre éstas, actualizándose cada cierto tiempo a partir de los datos observados históricamente y de la información proveniente de nuevas evidencias en el tiempo. Para lograr la característica dinámica, los autores utilizan funciones de puntuación (Scoring Function) en un espacio de búsqueda donde se aplica un algoritmo para hacer la selección de la red Bayesiana que mejor modela los datos de entrada. Como ejemplo de aplicación, los autores proponen un sistema de diagnóstico para el motor de un vehículo. El sistema propuesto se compone de cinco módulos: módulo de adquisición de datos, módulos de razonamiento y aprendizaje, módulo de conocimiento, módulo de salida y módulo de interfaz hombre-máquina. Los sensores en el módulo de adquisición recogen la información de estado del vehículo y del entorno. Esta información es almacenada y procesada y queda disponible para el motor de inferencia. El módulo de conocimiento almacena las reglas para el diagnóstico de las fallas y el modelo del motor de inferencia. El módulo de razonamiento y aprendizaje, se encarga de obtener datos almacenados en la base datos y usa una variedad de algoritmos de aprendizaje de redes Bayesianas, para modificar la estructura y los parámetros de la red, además crea las tareas de diagnóstico y se coordina con el motor de inferencia para realizar el diagnóstico a partir de la evidencia. El módulo de salida interpreta el resultado de la inferencia entregada como diagnóstico para facilitar la toma de decisiones a través de la interfaz hombre-máquina. Para corroborar la validez del método, dos pruebas experimentales son mostradas en el artículo. La primera, evalúa la capacidad del método para determinar la estructura de red más adecuada, para lo cual se compara la estructura arrojada por el sistema con una estructura genérica previamente diseñada. En este caso los autores sostienen que si se cuenta con un adecuado conjunto de datos de entrenamiento, el modelo de red aprendido es consistente con el modelo genérico original. Una segunda prueba evalúa la capacidad para diagnosticar una falla en el sistema de combustible de un vehículo, del cual se tienen 6000 conjuntos de datos estadísticos históricos, divididos en dos grupos para simular la variación temporal de los datos entrando al sistema de inferencia. De cada grupo, los primeros 2500 conjuntos de datos son usados para entrenamiento y 500 son usados para testeo. Los resultados obtenidos en el diagnóstico de las fallas con este sistema son comparados con los obtenidos con un sistema de diagnóstico tradicional (estático), sobre el mismo conjunto de datos, mostrando mejoría tanto en la detección correcta de fallas, como en el rechazo de falsas alarmas.

Hasta aquí se han recogido varios artículos donde se muestran una serie de aplicaciones en torno a la detección y diagnóstico de fallas con la teoría Bayesiana. En la Tabla 2-2 se resumen algunas de estas aplicaciones mostrando los aspectos más relevantes que se buscaban identificar: la fuente de

conocimiento utilizada, la arquitectura propuesta, la forma de prueba e implementación y los resultados obtenidos.

En los artículos revisados se pueden identificar algunos aspectos comunes en los aspectos evaluados:

- Fuente de conocimiento. Expertos en el sistema y/o registros históricos.
- Arquitectura propuesta: variada. En los artículos se exponen diferentes arquitecturas que normalmente están estrechamente ligadas al ejemplo de aplicación.
- Implementación. Simulada. En los artículos se coincide en la dificultad para inducir fallas en el sistema real, por ello se opta por realizar procedimientos de simulación que permitan generar información necesaria para el diseño y para la validación.

A partir de la información recogida en la documentación revisada se construyó una propuesta para el procedimiento de diseño en el que se busca sobre todo, facilitar la construcción topológica y paramétrica de la red, simplificando los mecanismos para la extracción del conocimiento que permitan llegar rápidamente a un sistema de diagnóstico cuyo funcionamiento se puede refinar una vez esté construido.

Tabla 2-2. Resumen aplicaciones detección y diagnóstico de fallas

Caso de estudio	Fuente de conocimiento	Arquitectura propuesta	Implementación	Resultados	Observaciones
Tennessee Eastman Process. Simulador de planta química industrial. [19]	Se generan bases de datos del sistema en funcionamiento normal y en funcionamiento con fallas. Las simulaciones se hicieron de forma separada, se recolectaron datos en funcionamiento normal, y datos en presencia de cada falla simulada.	Red Bayesiana con una capa de fallas, capa de reconocimiento de patrones y capa de variables.	Simulada.	90% de exactitud en la detección de la falla.	Realiza detección y diagnóstico. Se utilizan los valores normales en estado estable de las variables para definir el estado normal del sistema. Se utiliza la desviación de estos valores para determinar la presencia de una falla.
Combinación de redes Bayesianas con Razonamiento basado en casos (Case-Based Reasoning) [23]	No tiene un caso de estudio en particular y no especifica la fuente de conocimiento. Asume que las variables ya están identificadas y establece la relación entre éstas a partir del método Chi Square Test.	Red Bayesiana construida a partir de las relaciones obtenidas con el método Chi Square Test.	Simulada	Utiliza cuatro indicadores para evaluar el desempeño de la técnica, comparada con una red bayesiana común. Precisión, confiabilidad y velocidad. En todos los casos se obtuvo mejor comportamiento del sistema híbrido, más aún cuando el número de nodos de la red crece.	Solo realiza diagnóstico de falla. No menciona la etapa de detección de la falla.
Sensores climáticos distribuidos. [21]	Base de conocimiento construida con la ayuda de científicos expertos. Tiene una base de datos de cerca de 15 años de información.	Red Bayesiana cuyas relaciones se obtienen a partir del PMCC (Pearson product-moment correlataion coefficient)	Simulada	Se enfoca en resaltar la herramienta obtenida e indica algunos diagnósticos asertivos.	Se enfoca más en el procedimiento y diseño de la herramienta que en los resultados obtenidos.
Red celular GSM 2G. [24]	Modelo construido a partir de conocimiento de expertos. Modelo construido a partir de casos de entrenamiento. Se desarrolló una herramienta para la recolección de información generada por los expertos.	Bayesian Classifier. BN: Simple Bayes Model (Naïve Bayes Model), Central Bayes Model, Independence of Causal Influence.	Software de diagnóstico en una red real. No requiere intervención física en la red.	Promedio de exactitud del diagnóstico 67%.	Se enfoca en la detección y diagnóstico de fallas usando indicadores de desempeño en lugar de alarmas. La etapa de detección de la falla no se aborda, solo el diagnóstico.

2.2. Fundamentación Teórica

En este apartado se presenta la fundamentación teórica en torno a los sistemas productivos y las redes Bayesianas.

La teoría aquí presentada fue consultada en varias fuentes referenciadas a lo largo de cada sección. La intención es presentar los conceptos básicos necesarios para entender los sistemas productivos desde el punto de vista de los mecanismos para detección de fallas y los conceptos básicos para entender como las redes Bayesianas pueden inferir la ocurrencia de eventos a partir de información estadística de un proceso. Un análisis más profundo, tanto de la teoría de sistemas productivos como de la teoría de redes Bayesianas, puede encontrarse en las referencias citadas.

2.2.1. Sistemas Productivos

Este trabajo de investigación está enfocado en el diseño de sistemas de detección y diagnóstico de fallas en sistemas productivos. Antes de determinar la metodología a seguir para diseñar el sistema de detección y diagnóstico de fallas, es necesario conocer al menos los aspectos generales de los sistemas productivos, para definir la manera en que la información puede ser recolectada, procesada e interpretada con el fin de obtener un diagnóstico ante una situación anormal.

La manufactura o producción es el proceso por el cual se transforman materias primas en productos útiles. En [25] se define un sistema productivo (o sistema de manufactura) como una red de maquinarias y contenedores que están conectados de forma apropiada (de acuerdo a una topología y secuencia) para cumplir ciertos tipos de procesos que hacen posible la producción de productos finales, con unas características específicas de calidad, geometría, tamaño, materiales, texturas, etc. Estas maquinarias tienen unos atributos característicos [26] tales como la operación técnica que realizan (cortar, doblar, calentar, etc), la capacidad de producción de piezas por unidad de tiempo, y la calidad y confiabilidad de la máquina propiamente dicha. En cuanto a los contenedores se distinguen atributos como la tecnología empleada para almacenar y mover partes (cajas, manipuladores, transportadores, etc) y la capacidad de guardar trabajo en proceso entre un par de operaciones continuas. Desde el punto de vista de la forma en que evolucionan las variables involucradas en el proceso, los sistemas productivos pueden clasificarse en dos grupos generales [26]: continuos y discretos. En esta clasificación, los sistemas de producción continuos son aquellos en que las variables evolucionan de forma continua con el tiempo, por ejemplo, en las industrias químicas, de materiales y energía, predominan los procesos de carácter continuo, mientras que en otras industrias como la automotriz, electrónica,

aeroespacial y otras, predominan los procesos de carácter discreto, donde lo que se tiene es un conjunto de operaciones que se ejecutan de forma independiente. Desde el punto de vista de la forma en que están organizadas las maquinarias y contenedores, los sistemas productivos se pueden clasificar también en dos grupos: líneas de producción serial y sistemas de ensamblado. En una línea de producción serial se tiene un grupo de unidades de proceso, organizadas de forma consecutiva, a través de las cuales son transportados los materiales y productos, siempre de una unidad a la siguiente. Por otro lado, los sistemas de ensamblado normalmente comprenden varias líneas de producción serial cuyos productos se combinan para generar el producto final. En [27] se menciona que los sistemas productivos también se pueden clasificar en estocásticos y determinísticos. Los sistemas estocásticos se caracterizan por tener propiedades aleatorias, por lo que la relación entre sus entradas, procesos y salidas solo puede analizarse de forma estadística. Por otro lado en los sistemas determinísticos existe una relación de causa-efecto entre las entradas y las salidas, es decir que para una entrada dada el sistema siempre responde con la misma salida. En este trabajo se centra la atención en este último tipo de sistemas, donde se pueden establecer las relaciones de causa-efecto entre las entradas y salidas.

Estas definiciones proveen una idea general de lo que es un sistema productivo. Sin embargo, para abordar el problema de detección y diagnóstico de fallas, es necesaria una visión holística en la que todas las partes del sistema productivo se toman en cuenta, así como la interacción entre éstas. Una visión holística de los sistemas productivos implica que deben tenerse en cuenta todos los componentes técnicos, partes físicas, operadores humanos y la forma en como está organizado el trabajo de producción [28]. Más aún, para la detección y diagnóstico de fallas, debe cambiarse la perspectiva tradicional en que se describe un sistema productivo en términos de materias primas de entrada, procesos y productos finales, para poder visualizar el sistema productivo como se muestra en la Figura 2-2, donde las entradas son estímulos (señales de control automático y señales de control manual) y parámetros de configuración, los procesos están asociados a la maquinaria que produce la transformación de las materias primas, y las salidas son las variables físicas y/o químicas de las cuales se puede obtener alguna información cuantificable, ya sea a través de instrumentación (variables instrumentadas) o a través de inspección de los operarios (variables no instrumentadas). De esta manera es posible predecir, a partir de modelos, cuál debería ser el comportamiento del sistema ante los estímulos de entrada, para contrastarlo con la información de estado real del proceso, que se encuentra codificada en el conjunto de variables de salida.




Figura 2-2. Visión general del sistema productivo.

En la figura anterior, se pueden distinguir los siguientes elementos.

Parámetros de configuración: un sistema productivo puede tener uno o más modos de funcionamiento. Por ejemplo, un sistema con tanques podría tener un modo de llenado de los tanques, un modo de regulación de nivel y un modo de vaciado de los tanques. Los parámetros de configuración definen el modo de funcionamiento y esto define el comportamiento esperado del sistema.

- **Señales automáticas de control:** corresponden a todas las señales eléctricas, electrónicas y/o mecánicas que los elementos de control automático, como computadores y PLC, envían a las máquinas del proceso para que ejecuten sus operaciones. Estas señales pueden estar asociadas a tareas como abrir y cerrar válvulas, regular la velocidad en motores, encender y apagar sistemas de calentamiento, etc.
- **Señales manuales de control:** corresponden a todas las señales eléctricas, electrónicas y/o mecánicas que los operadores del proceso envían a las máquinas para que ejecuten sus operaciones. Estas señales también pueden estar asociadas a la manipulación de válvulas, motores, sistemas de calentamiento, etc, pero no están incluidas en ningún lazo de control automático y son generadas por los operadores a través de elementos como pulsadores, interruptores, palancas, sistemas de poleas, etc.
- **Maquinaria:** corresponde a todos los elementos que intervienen en la transformación y transporte de la materia prima y productos intermedios, a lo largo de todo el sistema productivo.

- Variables instrumentadas: corresponden a todas las variables de las cuales se obtiene información cuantitativa, a través de instrumentos de medición electrónica, y cuyos valores se concentran en algún centro de información. Estas variables pueden medir la transformación de las materias primas y los productos intermedios a lo largo de la línea de producción, o medir el estado de la maquinaria involucrada en el proceso de producción.
- Variables no instrumentadas: Corresponden a todas las variables de las cuales se obtiene información cuantitativa a partir de la observación de los operarios al proceso. Estas variables suelen ser subjetivas, suelen tener valores difusos y dependen en gran medida de la experticia del operario que las observe.

2.2.2. Redes Bayesianas

Una red Bayesiana es un gráfico acíclico dirigido, compuesto de nodos, que representan variables aleatorias, unidos por arcos direccionados que cuantifican la relación causal entre éstos. El conjunto de variables se puede representar como $U = (A_1, A_2, A_3, \dots, A_n)$ y la red es una estructura que representa, de forma gráfica, la dependencia condicional entre las variables de U . En esta estructura, se pueden distinguir nodos padres y nodos hijos. Cada nodo hijo está conectado a uno o más padres a través de la dependencia condicional dada por el arco. Esta dependencia es representada por una tabla de distribuciones condicionales de la variable hija dado un conjunto de combinaciones de los valores de las variables padre. Según [20] estas propiedades de las redes Bayesianas se pueden resumir en los siguientes puntos:

- Contiene un conjunto de variables y un conjunto de arcos dirigidos entre las variables.
- Cada variable contiene un conjunto finito de estados mutuamente excluyentes.
- Las variables unidas con arcos dirigidos constituyen un gráfico acíclico dirigido (DAG – Directed Acyclic Graph). Para que el gráfico sea acíclico no debe haber un camino $A_1 \rightarrow A_2 \rightarrow A_3 \dots \rightarrow A_n$ tal que $A_1 = A_n$.
- Cada variable A , con padres $B_1, B_2, \dots, B_n$ tiene asociada una tabla de probabilidad condicional dada por $P(A/B_1, B_2, \dots, B_n)$.

Si una variable (nodo) A no tiene padres, la tabla de probabilidad condicional se reemplaza por la probabilidad incondicional $P(A)$. En la Figura 2-3 se muestra un ejemplo de gráfico acíclico dirigido, donde las probabilidades incondicionales $P(A)$ y $P(B)$ deben ser especificadas, y se muestran las probabilidades que deben calcularse para cada nodo.




Figura 2-3. Red Bayesiana simple - Grafico aciclico dirigido (Directed Aciclyc Graphic - DAG) [20]

La fundamentación de las redes Bayesianas parte del teorema de Bayes. Suponiendo que A y B son dos eventos aleatorios y que $P(B) > 0$, la probabilidad del evento A dado el evento B, se conoce como probabilidad condicional y puede escribirse como [29]:

$$P(A|B) = \frac{P(AB)}{P(B)} \quad \text{Ecuación 2-1}$$

Donde $P(AB)$ se conoce como probabilidad de unión y está dada por la ecuación

$$P(AB) = P(B)P(A|B) = P(A)P(B|A) \quad \text{Ecuación 2-2}$$

Además, suponiendo que $B_1, B_2, \dots, B_n$ son un conjunto de variables mutuamente excluyentes que satisfacen $\sum_{i=1}^n B_i = s$ donde s es la certeza del evento y $P(B_i) > 0, i = 1, 2, \dots, n$ para cualquier evento A dado, se obtiene la probabilidad marginal:

$$P(A) = \sum_{i=1}^n P(B_i)P(A|B_i) \quad \text{Ecuación 2-3}$$

Entonces, el teorema Bayesiano puede ser obtenido usando la probabilidad condicional y la probabilidad marginal:

$$P(B_i|A) = \frac{P(AB_i)}{P(A)} = \frac{P(B_i)P(A|B_i)}{\sum_{i=1}^n P(B_i)P(A|B_i)} \quad \text{Ecuación 2-4}$$

Se puede observar que este teorema provee una forma de calcular la probabilidad posterior de un evento, dada la probabilidad previa de la misma. La inferencia o diagnóstico de la red Bayesiana se da por la aplicación de este razonamiento.

A partir de este teorema se calculan entonces las probabilidades condicionales mostradas en la Figura 2-3. Para simplificar el cálculo de estas probabilidades y facilitar la inferencia, se puede asumir independencia entre los nodos. Con esto, la tabla de probabilidad para las uniones $P(U)$ puede ser calculada a partir de las probabilidades condicionales definidas en la red Bayesiana, usando la regla de la cadena [20]: para una red Bayesiana sobre el universo $U = (A_1, A_2, A_3, \dots, A_n)$, la distribución de probabilidad de unión $P(U)$ es el producto de todas las probabilidades condicionales especificadas en la red Bayesiana.

$$P(U) = \prod P(A_i | pa(A_i)) \quad \text{Ecuación 2-5}$$

Donde $pa(A_i)$ es el conjunto de padres de la variable A_i . Jensen, citado en [20], probó este teorema aplicando inducción en el número de variables del universo U . Para la red mostrada en la Figura 2-3, la distribución de probabilidad de unión se puede calcular como:

$$P(A_1, A_2, A_3, A_4, A_5) = \prod_{i=1}^5 P(A_i | A_1, \dots, A_{i-1})$$

$$P(A_1, A_2, A_3, A_4, A_5) = P(A_1)P(A_2|A_1)P(A_3|A_1A_2)P(A_4|A_1A_2A_3)P(A_5|A_1A_2A_3A_4) \quad \text{Ecuación 2-6}$$

En cuanto a la mecánica para determinar la estructura de la red, existen diferentes aproximaciones. En [6] se definen tres posibles formas para obtener dicha estructura:

- Basado en la búsqueda del conocimiento acerca del sistema (knowledge elicitation), de manera que se pueda establecer, a través de modelos, la relación entre las variables del mismo.
- Basado en manuales del sistema y conocimiento del proceso por expertos humanos.
- Basado en métodos de aprendizaje usando bases de datos y registros de operaciones pasadas.

Los primeros dos métodos son altamente dependientes de los supuestos que los expertos en el sistema productivo puedan hacer.

En cuanto al aprendizaje estructural a partir de información histórica, en [30] se menciona que existen diversos algoritmos que pueden ser divididos en dos grupos: de búsqueda y puntuación (search & scoring), y análisis de dependencia. En [31] se puede encontrar un resumen de algunos algoritmos utilizados para aprendizaje estructural y se plantean dos métodos (TPDA – Three phase learning algorithm with given node ordering, TPDA- π Three phase learning algorithm without node ordering) que se basan en definir arcos entre los nodos de la red y evaluar si estos arcos son correctos o no. En [30] se menciona el algoritmo de aprendizaje estructural K2 (Bayesian-score) desarrollado en [32], que se basa en definir varias estructuras de red y escoger aquella que maximice la relación de dependencia entre las variables del conjunto de datos. Por otro lado, en [33] se comparan distintas técnicas de clasificación para detección de fallas, tales como árboles de decisión, redes neuronales, máquinas de vectores de soporte y el clasificador Bayesiano basado en la red Bayesiana tipo Naive, obteniendo los mejores resultados con éste último.

Después de analizar las distintas técnicas de aprendizaje estructural encontradas, se decidió trabajar con la red Bayesiana tipo Naive, principalmente por dos razones:

- Simplicidad en la construcción. La estructura de la red no depende de las suposiciones de los expertos, ni se requiere del conjunto de datos históricos para su análisis y construcción. Al iniciar el proyecto, no se contaba con registros históricos de ejemplo en los casos de estudio, y el usar la red Naive permite avanzar fácilmente en este tipo de escenarios.
- Simplicidad de ampliación. Dada la simplicidad de la red Naive, la inclusión de nuevas fallas y nuevos síntomas se hace muy fácilmente.

2.3. Resumen del capítulo

En este capítulo, a partir de las referencias bibliográficas consultadas, se pudieron establecer algunas tendencias en cuanto a la metodología utilizada para diseñar sistemas de detección y diagnóstico de fallas en distintas aplicaciones. Se pudieron evidenciar cuáles son las fuentes de información utilizadas para la construcción paramétrica y topológica de las redes usadas en las aplicaciones, así como las técnicas utilizadas para tratar esta información y extraer los datos relevantes.

En cuanto a los sistemas productivos, se puntualizaron definiciones muy genéricas encaminadas a dar una visión general de éstos, y a partir de la cual se puede pensar en el diseño de los sistemas de diagnóstico para algún sistema productivo

en particular, teniendo presente que el sistema productivo se observa en términos de las variables que en él se miden y sus parámetros de configuración.

La teoría Bayesiana se introdujo pensando sólo en aplicaciones que involucran una red Bayesiana como tal, sin tener en cuenta otras formas de aplicación de la teoría de Bayes. En ese sentido, este proyecto de investigación se enfoca en la aplicación de la teoría de Bayes en topologías de red para producir los diagnósticos de las fallas. Más aún, el proyecto se centra en cómo se usa la herramienta de redes Bayesianas y no en cómo funciona, por ello el objetivo primario en el procedimiento de diseño se concentra en definir la topología de la red y sus parámetros de configuración.

En el siguiente capítulo se presenta la propuesta obtenida para el diseño del sistema de detección y diagnóstico, teniendo en cuenta las consideraciones anteriores.

3. PROPUESTA

En este capítulo se presenta el procedimiento propuesto para la construcción de sistemas de detección y diagnóstico de fallas, en sistemas productivos. El procedimiento propuesto busca generalizar los pasos para la construcción del sistema de detección y diagnóstico de fallas, teniendo en cuenta que el objetivo de éste sistema es proveer información acerca de la integridad y el correcto funcionamiento del sistema productivo. Los pasos propuestos en este apartado fueron probados utilizando el toolbox de redes bayesianas para Matlab, que se encuentra disponible en [34].

3.1. Desarrollo de un sistema de diagnóstico con redes bayesianas

En este trabajo se propone una mecánica para el diseño de un sistema de diagnóstico basado en redes Bayesianas. Tomando como punto de partida el esquema general del sistema productivo, mostrado en la Figura 2-2, a continuación se muestra, en la Figura 3-1, el esquema general del sistema de diagnóstico propuesto.




Figura 3-1. Diagrama General del Sistema Propuesto

El sistema se compone de dos bloques, un bloque *OBSERVADOR* cuyo objetivo es monitorear el proceso y arrojar un vector de síntomas donde se codifican los estados normales y/o anormales de las variables observadas, y un bloque de

DIAGNÓSTICO cuyo objetivo es interpretar el vector de síntomas y determinar la falla que probablemente está asociada al estado de las variables.

Para lograr este diseño, se proponen los pasos mostrados en la Figura 3-2. El proceso se inicia delimitando el caso de estudio, donde se listan las variables del sistema productivo que serán observadas (medidas) y que servirán como síntomas (nodos hijos) de la red Bayesiana de diagnóstico. Identificadas las variables observadas se define el bloque OBSERVADOR que se encargará de calcular el estado de las variables observadas de acuerdo a los comportamientos normales esperados en cada una. Para realizar este cálculo, el bloque OBSERVADOR debe ser un sistema experto, un conjunto de reglas condicionales, un operario experto, un modelo matemático del sistema productivo o cualquier otra metodología que permita establecer la diferencia entre el estado esperado y el estado real de las variables medidas. Luego, debe definirse el conjunto de fallas conocidas del sistema productivo, que servirán como nodos padre de la red, y enseguida debe establecerse cómo estas fallas afectan a cada uno de los síntomas. A partir de la relación entre las fallas y los síntomas, se establece la topología de la red y finalmente se hace la construcción paramétrica, en la que se definen las probabilidades asociadas a cada nodo de la red. En la Figura 3-2 se observan también dos pasos que son opcionales, estos son la identificación de fallas con sintomatología idéntica y la agrupación de fallas con síntomas iguales. Si bien el sistema de diagnóstico puede diseñarse sin tener en cuenta estos pasos, la inclusión de los mismos permite reducir el número de probabilidades a determinar y por consiguiente el peso computacional del sistema de diagnóstico final. Ejecutado este procedimiento se obtiene como resultado el sistema de diagnóstico. Este sistema de diagnóstico generará un DIAGNÓSTICO de acuerdo a los valores de las variables observadas en un momento determinado. Las acciones en campo tomadas para la corrección de la falla identificada, darán información acerca de lo asertiva que fue la predicción. A partir de esta información se decide si el sistema de diagnóstico se deja sin modificaciones, si es necesario incluir nuevos síntomas, nuevas fallas o sólo ajustar parámetros. En caso de requerir la inclusión de nuevos síntomas, es necesario pasar de nuevo por todas las etapas del procedimiento, ya que la inclusión de nuevos síntomas implica la modificación del observador para incluir la nueva variable, afecta la relación entre los síntomas y las fallas, afecta la topología y amplía la cantidad de probabilidades que se deben definir. En caso de requerir la inclusión de nuevas fallas sólo sería necesario retomar el procedimiento desde la definición del listado de fallas, establecer la relación de los síntomas con la nueva falla, modificar la topología con el nuevo nodo y obtener las nuevas probabilidades. Por último, en caso de que se requieran ajustar parámetros (probabilidades) solo se retoma éste último paso del procedimiento. Cabe resaltar que para este proyecto, son abordadas las etapas del procedimiento de diseño del sistema de diagnóstico. Las mecánicas de ajustes para inclusión de nuevos síntomas, nuevas fallas y ajustes paramétricos se plantean como una posibilidad para trabajos posteriores.




Figura 3-2. Pasos para el diseño del sistema de diagnóstico

A continuación se describen en detalle cada uno de los pasos del procedimiento de diseño, mostrados en la Figura 3-2.

3.1.1. Delimitar el caso de estudio

Este paso comprende listar todas las variables observables del proceso, así como la descripción de los valores alcanzados por las mismas, identificando los rangos que definen los estados normales y anormales de cada variable. Cabe destacar que las variables observables del proceso, son aquellas de las cuales se puede obtener alguna información cuantitativa, ya sea por instrumentación del proceso o por inspección manual de los operadores. Estas variables observadas serán los *síntomas* a partir de los cuales habrá de obtenerse el diagnóstico. La información puede registrarse de manera resumida como se muestra en el ejemplo de la Tabla 3-1.

Tabla 3-1. Plantilla general para la descripción de las variables del sistema

Tag	Descripción	Rango Normal	Anormalidad	
			Bajo	Alto
s1TV1	Descripción variable s1	Valor normal s1	Valor bajo	Valor alto
s2TV2	Descripción variable s2	Valor normal s2	Valor bajo	Valor alto
s3TV3	Descripción variable s3	Valor normal s3	Valor bajo	Valor alto
snTVn	Descripción de la n-ésima variable	Valor normal de sn	Valor bajo	Valor alto

En la tabla se pueden identificar los siguientes campos:

- **Tag.** Es el nombre con que se identifica la variable del proceso en el sistema de diagnóstico. Se recomienda usar un nombre compuesto, como el que se muestra en la tabla, para mantener la coherencia y facilitar la identificación de las variables tanto en el sistema de diagnóstico como en el sistema productivo. El nombre propuesto en la tabla se compone de dos partes: a) sN. El prefijo s indica que es una variable *síntoma* y N es un número consecutivo para identificar cada síntoma. b) TVN. Es el tag propio de la variable en el sistema productivo. Estos tag se encuentran normalmente en los planos de instrumentación del sistema productivo o en los P&ID (Process and Identification).
- **Descripción.** Breve descripción de la variable.
- **Rango Normal.** Indica los valores para los cuáles se considera que la variable está en el rango normal de operación. Esta información ayuda a construir el sistema observador.
- **Anormalidad Bajo.** Este valor indica el rango para el cual la medición de la variable se considera por debajo de la medida normal.

- Anormalidad Alto. Este valor indica el rango para el cual la medición de la variable se considera por encima de la medida normal.

3.1.2. Definir el sistema observador

El objetivo del observador es monitorear el proceso, comparar las mediciones de las variables observadas con las mediciones esperadas y determinar un conjunto de valores que indican el estado de cada variable respecto de su valor teórico. Este conjunto de valores de las variables observadas, o síntomas, se conocerá como el *vector de síntomas* en el que se codifican los estados de cada variable en valores discretos, “Normal”, “Bajo” o “Alto”, donde cada valor indica el estado de la medición en relación con el valor esperado para ésta.

La idea es tener un modelo del proceso a partir del cual se puede conocer la medición esperada en las variables observadas. Esta medición esperada se compara con la medición real arrojada por los sensores del sistema productivo, indicando para cada variable si está en el rango normal “N”, si está por debajo del rango esperado “B”, o si está por encima del rango esperado “A”. El modelo del proceso puede ser construido a partir de las ecuaciones que gobiernan el mismo, se pueden usar sistemas expertos, redes neuronales, un conjunto de reglas condicionales o puede ser un operario experto que conozca el proceso. En el ejemplo de la Figura 3-3, el observador arroja un vector de síntomas donde la variable S1TV1 tiene un estado “Alto”, la variable S2TV2 tiene un estado “Bajo” y la variable S3TV3 tiene un estado “Normal”.




Figura 3-3. Diagrama General Observador

En el sistema observador se debe definir la frecuencia con que se determina el estado de las variables del proceso y generar el vector de síntomas en los tiempos correctos de acuerdo a la frecuencia establecida. En la Tabla 3-2 se muestra un ejemplo en el que el sistema observador monitorea el sistema productivo con un periodo T . Durante un rango de tiempo, el comportamiento del sistema productivo

es normal y en el instante $t5$ el vector de síntomas indica que hay variables cuyo estado no es normal.

Tabla 3-2. Plantilla general del vector de síntomas

Tiempo	Estados (Vector de Síntomas)		
	S1TV1	S2TV2	S3TV3
$t1$	Normal "N"	Normal "N"	Normal "N"
$t2 = t1+T$	Normal "N"	Normal "N"	Normal "N"
$t3 = t2+T$	Normal "N"	Normal "N"	Normal "N"
$t4 = t3+T$	Normal "N"	Normal "N"	Normal "N"
$t5 = t4+T$	Alto "A"	Bajo "B"	Normal "N"

En sistemas productivos complejos estos modelos pueden necesitar la inclusión de parámetros de configuración y modos de operación. Por ejemplo, en un sistema productivo que involucre operaciones como llenado de un tanque, regulación del nivel del tanque y vaciado del tanque, se podrían definir al menos tres modos de operación diferentes para los cuáles el comportamiento "normal" de un sensor de nivel asociado al tanque puede variar. Durante la operación de llenado, lo "normal" para el sensor de nivel sería medir una variación positiva de nivel definida por el sistema de control, durante la regulación, lo "normal" sería que la variación en el sensor de nivel se mantenga en lo posible nula, y durante el vaciado lo "normal" sería medir una variación negativa de nivel de acuerdo a las órdenes del sistema de control.

3.1.3. Listar las fallas conocidas

En esta etapa del procedimiento se deben listar las fallas para las cuales estará preparado el sistema de diagnóstico. El objetivo es que el sistema de diagnóstico pueda asociar un patrón de síntomas con alguna de las fallas establecidas en este listado. Para obtener el listado de fallas, se puede recurrir al registro histórico del sistema productivo o a la experiencia de los operadores. Es importante al definir las fallas, tener en cuenta que cada falla incluida en el sistema de diagnóstico debe verse reflejada en al menos una de las variables síntoma, es decir, en la lista se debe evitar incluir alguna falla que no aporte de alguna manera a al menos uno de los síntomas. En ese sentido, en esta etapa conviene identificar si cada síntoma se afecta o no en cada una de las fallas listadas. De esta manera se pueden descartar fallas que no se puedan diagnosticar con el conjunto de variables escogidas, o decidir la inclusión de variables síntomas adicionales. El listado de fallas se puede consignar en una plantilla como la mostrada en la Tabla 3-3. En esta misma plantilla se identifican los síntomas que afecta cada falla.

Tabla 3-3. Plantilla general del listado de fallas y los síntomas que afectan

Falla		Síntomas que afecta			
Tag	Descripción	S1	S2	S3	Sk
F1	Descripción falla 1	No	Si	No	No
F2	Descripción falla 2	Si	No	No	No
F3	Descripción falla 3	Si	No	No	Si
Fn	Descripción falla n	No	No	Si	No

En la tabla anterior se distinguen los siguientes campos:

- Tag. Identificador de la falla. Se recomienda el prefijo *F* para identificar que es una falla, y una numeración consecutiva.
- Descripción. Es una descripción breve de la falla.
- Síntomas que afecta. Este campo permite establecer que síntomas afecta cada falla. Todas las fallas deben afectar al menos un síntoma.

En el ejemplo de la Tabla 3-3, la falla F1 afecta el síntoma S2, la falla F2 afecta el síntoma S1, la falla F3 afecta los síntomas S1 y Sk, y la falla Fn afecta el síntoma S3.

Observe que en esta etapa se pueden definir las fallas y los síntomas que afectan sin entrar en detalle de cuánto ni cómo se afecta cada síntoma, ya que este proceso se aborda más adelante.

Para definir si un síntoma es afectado o no por una falla, se pueden seguir distintas aproximaciones. La primera y más sencilla sería preguntar a un experto y que éste defina para cada síntoma si es o no afectado en cada falla. La opinión de este único experto sería la fuente para rellenar la información de la Tabla 3-3.

Una segunda aproximación sería consultar a varios expertos y ponderar la opinión de estos. Por ejemplo, se podría preguntar a cada experto: *¿cuando la falla F1 se presenta, la variable síntoma S1 sale de su rango normal?* La opinión de todos los expertos se podría tabular y ponderar como se muestra en la Tabla 3-4.

Tabla 3-4. Plantilla opinión de expertos sobre afectación de síntomas

Falla	Síntoma S1				Ponderación	Decisión Final
	Experto 1	Experto 2	Experto 3	Experto 4	% Si	
	25%	25%	25%	25%		
F1	Si	No	No	No	25%	No
F2	Si	Si	Si	No	75%	Si
F3	No	Si	Si	Si	75%	Si
Fn	No	No	Si	No	25%	No

En la Tabla 3-4 se han indicado las opiniones de cuatro expertos, respecto de si cada falla afecta o no a la variable síntoma S1. Para cada experto se ha asignado una ponderación del 25%, esto significa que la opinión de todos los expertos es igualmente válida. Esta ponderación podría ajustarse si hay expertos cuya opinión es más valiosa dado el rango y la experiencia en el sistema productivo. De la Tabla 3-4, la columna que dice “Decisión final” sería la que se usa para rellenar los valores correspondientes en la Tabla 3-3.

Otra aproximación en que se podría pensar, si se cuenta con los registros históricos del sistema productivo, sería contar la cantidad de ocurrencias de una falla, y en éstas ocurrencias, la cantidad de veces que un síntoma estuvo por fuera del rango de valores considerado normal, teniendo en cuenta que éste rango de normalidad ha sido definido previamente al delimitar el caso de estudio (ver Tabla 3-1). En Tabla 3-5 se han registrado la cantidad de veces que ocurre una falla y la cantidad de veces (en estas ocurrencias) que un síntoma S1 es afectado.

Tabla 3-5. Plantilla Frecuencia de ocurrencia de Fallas y efecto sobre los síntomas

Falla	Cantidad de ocurrencias de la falla	Cantidad de veces que el síntoma S1 salió del rango normal, al presentarse la falla	Porcentaje de veces que la falla afectó al síntoma	Decisión final
F1	10	2	$2/10 = 20\%$	No
F2	3	3	$3/3 = 100\%$	Si
F3	13	11	$11/13 = 84,6\%$	Si
Fn	12	3	$3/12 = 25\%$	No

De la Tabla 3-5 la columna que dice “Decisión Final” es la que se usaría para rellenar la columna correspondiente en la Tabla 3-3.

3.1.4. Relacionar fallas y síntomas

El objetivo de esta etapa es establecer, de forma cualitativa, la relación entre las fallas listadas y las variables de síntomas definidas en las etapas anteriores. Así, en esta etapa debe definirse cómo afecta la presencia de cada falla a cada uno de los síntomas, teniendo en cuenta que cada síntoma puede asumir uno de tres valores, “Normal”, “Bajo” y “Alto”. Para cumplir con esto, pueden consultarse los registros históricos del sistema productivo y establecer cuál es el comportamiento de las variables síntoma cuando hay una falla presente, o se puede consultar a los expertos cuál es el comportamiento habitual de cada variable ante la presencia de cada falla.

Siguiendo con el ejemplo de la Tabla 3-3, si se decide consultar a los expertos por estos estados normales, se les podría preguntar por ejemplo, *cuál es el estado que normalmente asumen las variables (síntomas) cuando la falla F1 está presente*. A esto los expertos podrían responder que *cuando la falla F1 se presenta, lo normal es que el síntoma S1 esté en estado “Normal”, que el síntoma S2 esté en estado “Alto”, que el síntoma S3 esté en estado “Normal” y que el síntoma Sk esté en estado “Normal”*. Igualmente se pregunta por la sintomatología normal cuando se presenta la falla F2, a lo que los expertos podrían responder que *lo normal, cuando la falla F2 se presenta, es que S1 esté en estado “Bajo”, S2 en estado “Normal”, S3 en estado “Normal” y Sk en estado “Normal”*. Luego, se preguntaría por la sintomatología normal cuando la falla F3 se presenta, a lo que los expertos podrían responder que *lo normal, cuando la falla F3 se presenta, es que S1 esté en estado “Bajo”, S2 en estado “Normal”, S3 en estado “Bajo” y Sk en estado “Alto”*. Finalmente se preguntaría por la sintomatología cuando se presente la falla Fn, en cuyo caso los expertos podrían responder que *lo normal es que el síntoma S3 esté en estado “Alto”, mientras los demás síntomas se mantienen en estado “Normal”*. Esta información aportada por los expertos se podría resumir en una plantilla como la mostrada en la Tabla 3-6. En la Tabla 3-7 se presenta esta misma plantilla con valores de ejemplo.

Tabla 3-6. Plantilla general de los estados normales de los síntomas ante cada falla.

Falla Presente	Estados normales de los síntomas ante las fallas			
	S1	S2	S3	Sk
No Falla	Normal	Normal	Normal	Normal
F1	Estado de S1 ante la falla F1	Estado de S2 ante la falla F1	Estado de S3 ante la falla F1	Estado de Sk ante la falla F1
F2	Estado de S1 ante la falla F2	Estado de S2 ante la falla F2	Estado de S3 ante la falla F2	Estado de Sk ante la falla F2
F3	Estado de S1 ante la falla F3	Estado de S2 ante la falla F3	Estado de S3 ante la falla F3	Estado de Sk ante la falla F3
Fn	Estado de S1 ante la falla Fn	Estado de S2 ante la falla Fn	Estado de S3 ante la falla Fn	Estado de Sk ante la falla Fn

Tabla 3-7. Plantilla general de estados normales de los síntomas ante cada falla, con valores de ejemplo.

Falla Presente	Estados normales de los síntomas ante las fallas			
	S1	S2	S3	Sk
No Falla	Normal	Normal	Normal	Normal
F1	Normal	Alto	Normal	Normal
F2	Bajo	Normal	Normal	Normal

F3	Bajo	Normal	Bajo	Alto
Fn	Normal	Normal	Alto	Normal

Si se deciden utilizar los registros históricos para extraer esta información, se podría contar cuántas veces el síntoma estuvo en cada estado dado que la falla estaba presente. Por ejemplo, siguiendo lo planteado en la Tabla 3-5 se podría contar, de las diez (10) veces que se presentó la falla F1, cuántas veces el síntoma S1 estuvo “Normal”, cuántas veces estuvo “Alto” y cuántas veces estuvo “Bajo”, y se podría asumir como valor habitual del síntoma S1 ante la presencia de la falla F1, aquel que obtenga el mayor número de cuentas.

Tabla 3-8. Plantilla estados de un síntoma en presencia de cada falla

Falla	Cantidad de ocurrencias de la falla	Síntoma S1			
		Cantidad de veces en “Normal”	Cantidad de veces en “Alto”	Cantidad de veces en “Bajo”	Decisión Final
F1	10	8	2	0	Normal
F2	3	0	0	3	Bajo
F3	13	2	1	10	Bajo
Fn	12	9	1	2	Normal

En la Tabla 3-8 se muestra, por ejemplo, que la falla F1 se presenta diez (10) veces; que de estas diez veces, ocho (8) veces el síntoma S1 permanece en estado “Normal”, dos (2) veces se pone en estado “Alto” y cero (0) veces se pone en estado “Bajo”, por consiguiente, lo habitual es que ante la falla F1 el síntoma S1 permanezca en estado “Normal”. Para el caso de la falla F3, que se presenta trece (13) veces, el síntoma S1 permanece en estado normal dos (2) veces, se pone en estado “Alto” una (1) vez y se pone en estado “Bajo” diez (10) veces, por lo tanto lo habitual es que ante la falla F3 el síntoma S1 se ponga en estado “Bajo”.

Con la información recopilada hasta este punto se puede plantear la topología de la red para el sistema de diagnóstico. Sin embargo existen dos pasos adicionales en el procedimiento que son opcionales, estos son la identificación de síntomas idénticos y la agrupación de fallas con sintomatología idéntica. Si bien el sistema puede funcionar sin realizar estos pasos, como se observará más adelante, el incluirlos reduce el costo computacional del sistema de diagnóstico final. Por lo pronto se continuará con la descripción del procedimiento sin tener en cuenta estos dos pasos que serán abordados en secciones posteriores.

3.1.5. Definir la topología

El sistema de diagnóstico propuesto se basa en la red Bayesiana tipo Naive, cuya estructura se muestra en la Figura 3-4. .




Figura 3-4. Forma General Red Bayesiana tipo Naive

Esta red se compone de un conjunto de nodos padre, identificados en la Figura 3-4 con f_1 , f_2 , f_n , y un conjunto de nodos hijos, identificados en la misma figura como s_1 , s_2 , s_k . En este tipo de red, todos los nodos hijos están relacionados con todos los nodos padre. La idea es que los nodos padre corresponden a las fallas conocidas del proceso y los nodos hijos corresponden a las variables observadas del proceso (síntomas). Según la figura, se tienen n fallas conocidas y k variables observadas o síntomas.

Una de las principales propiedades de las redes Bayesianas es que permiten identificar de manera visual la relación causal que existe entre los nodos. En el campo del diagnóstico de fallas, esta propiedad permitiría visualizar que nodos de falla están directamente relacionados con los diferentes síntomas. Sin embargo en la estructura propuesta, donde todos los nodos padre se relacionan con todos los nodos hijos, esta propiedad prácticamente se diluye ya que todas las fallas se asocian a todos los síntomas. Esto se hizo con el fin de facilitar la construcción topológica, ya que en algunos escenarios es difícil establecer exactamente que síntomas son afectados por cada falla. De esta manera, el peso de la relación entre un nodo de falla y un nodo síntoma recae sobre las probabilidades condicionadas que serán en últimas las que definan que tan relacionado está un estado de un nodo síntoma con un estado de un nodo falla.

3.1.6. Definir probabilidades

Esta etapa comprende la construcción paramétrica de la red. En ésta se definen las probabilidades asociadas a cada uno de los arcos o conexiones de la red.

Para la construcción paramétrica deben tenerse en cuenta los estados que puede asumir cada nodo de la red. Estos estados definirán la cantidad de probabilidades que deben obtenerse.

Para los nodos padre se define que sólo pueden tener dos posibles estados: “Presente” y “No presente”. Estos estados indican que ante un conjunto de síntomas dado, el nodo padre (o falla) está “Presente” o “No está presente”. Visto desde otro punto de vista, un nodo padre que esté en estado “Presente” producirá un patrón determinado en los nodos hijos (o síntomas). Este patrón de síntomas está dado por los posibles estados que pueden asumir los nodos hijos, que se han definido como “Normal”, “Alto” y “Bajo”. En la Figura 3-5 se muestra un ejemplo en que el nodo padre F2 está en estado “Presente - P” y los demás nodos padre están en estado “No Presente - NP”. El estado “Presente” del nodo F2, producirá un patrón de estados en los nodos hijos (síntomas). Para el ejemplo, este patrón de síntomas es “Normal - N” para el nodo S1, “Bajo - B” para el nodo S2, “Alto - A” para el nodo S3 y “Normal - N” para el nodo Sk. Esto significa que si la falla F2 está presente en el sistema productivo, la variable (síntoma) S1 estará “Normal”, la variable S2 estará en estado “Bajo”, la variable S3 estará en estado “Alto” y la variable Sk estará en estado “Normal”.




Figura 3-5. Ejemplo patrón de síntomas ante una falla

Teniendo en cuenta los posibles estados definidos para los nodos padre y los nodos hijos, se deben establecer las probabilidades condicionadas de los estados de los nodos hijos dada la ocurrencia de los estados de los nodos padre, y las probabilidades a priori de los estados de los nodos padre. Debe considerarse que los nodos padre se definieron como las fallas conocidas del sistema y los nodos hijos como las variables síntoma del sistema. Esto significa entonces que deben definirse las probabilidades de que los síntomas asuman cierto estado, dada la ocurrencia de las fallas, y las probabilidades de que ocurran las fallas dadas las características del sistema productivo.

Estas probabilidades se pueden determinar a partir de la experiencia de los operarios o a partir de los registros históricos del sistema productivo.

Para determinar la probabilidad a priori de ocurrencia de las fallas a partir de los registros históricos, se pueden tomar un conjunto de registros en un periodo de tiempo representativo, teniendo en cuenta las características del sistema productivo, contar el número total de fallas ocurridas en ese periodo y determinar la frecuencia con que ocurre cada una de las fallas. Este cálculo arroja la

probabilidad a priori del estado “Presente” de cada falla. Para obtener la probabilidad del estado “No Presente” se resta al 100% la probabilidad del estado “Presente”. Por ejemplo, en la Tabla 3-9 se muestra el cálculo de las probabilidades en un sistema productivo donde los expertos han determinado que el periodo de tiempo representativo es un (1) año.

Tabla 3-9. Ejemplo probabilidades a priori a partir de registros históricos

Ítem	Valor	Probabilidad a priori de que la falla ocurra (estado “Presente”).	Probabilidad a prior de que la falla no ocurra (estado “No presente”).
Periodo de tiempo	365 días (1 año)		
Total fallas ocurridas	37 Fallas		
Total ocurrencias Falla F1	1 vez	$1/37 = 2,7\%$	97.3%
Total ocurrencias Falla F2	3 veces	$3/37 = 8,1\%$	90.9%
Total ocurrencias Falla F3	13 veces	$13/37 = 35,1\%$	64.9%
Total ocurrencias Falla F4	15 veces	$15/37 = 40,5\%$	59.5%
Total ocurrencias Falla F5	5 veces	$5/37=13,5\%$	86.5%

Otra forma para determinar la probabilidad a priori de las fallas, es a partir del conocimiento de los expertos. Para ello se puede pedir a cada experto que indique la probabilidad de ocurrencia de cada falla, de acuerdo a la Tabla 2-1, donde se muestra la escala de probabilidad condicionada. Con la opinión de todos los expertos, se puede obtener un promedio para la probabilidad de ocurrencia de cada falla y finalmente normalizar para que la sumatoria de todas las probabilidades a priori sea el 100%.

Tabla 3-10. Ejemplo probabilidades a priori a partir de encuesta a los expertos

	Opinión Experto 1		Opinión Experto 2		Opinión Experto 3		Prom.	Normalizado. Estado “Presente”
Falla 1	Improb.	15%	Improb.	15%	Improb.	15%	15%	9%
Falla 2	Incierto	25%	Improb.	15%	Incierto	25%	21,7%	13%
Falla 3	Incierto	25%	50-50	50%	Incierto	25%	33,3%	20%
Falla 4	Esperado	75%	Esperado	75%	Esperado	75%	75,0%	45%
Falla 5	Improb.	15%	Incierto	25%	Incierto	25%	21,7%	13%
TOTALES							166,7%	100%

En la Tabla 3-10 se muestra el ejemplo de las probabilidades a priori para las mismas fallas listadas en la Tabla 3-9. Estas probabilidades son aportadas por los expertos de acuerdo a la Tabla 2-1. Se observa que las probabilidades a priori obtenidas para el estado “Presente” no son exactamente las mismas, lo cual es normal dada la naturaleza diferente de las fuentes de información. Sin embargo, aun cuando las probabilidades no son exactamente iguales, la esencia de la distribución de las probabilidades se mantiene, esto significa que la falla F4 sigue teniendo la probabilidad de ocurrencia más alta y la falla F1 sigue teniendo la

probabilidad de ocurrencia más baja. Cabe destacar que una vez el sistema entre en funcionamiento, se puede llevar un control más minucioso de la ocurrencia de las fallas, con lo que estas probabilidades a priori podrían ajustarse.

Otra posible aproximación para determinar las probabilidades a priori de las fallas, sería distribuir la probabilidad del estado “Presente” de manera uniforme entre todas las fallas. Esto podría utilizarse cuando no es posible obtener los registros históricos, cuando no es posible tener acceso a los expertos o podría ser la configuración inicial del sistema de diagnóstico, que en etapas posteriores podría ajustarse. En la Tabla 3-11 se observa un ejemplo de las probabilidades a priori distribuidas de manera uniforme para las mismas fallas de la Tabla 3-9 y la Tabla 3-10. Si bien se observan diferencias considerables en las probabilidades asignadas, se han obtenido resultados satisfactorios usando esta aproximación, teniendo siempre presente que en etapas posteriores estas probabilidades deben ajustarse de acuerdo a la forma en que vayan ocurriendo las fallas.

Tabla 3-11. Ejemplo probabilidades a priori distribuidas de forma uniforme

Falla	Probabilidad ocurrencia estado “Presente”	Probabilidad ocurrencia estado “No Presente”
Falla 1	1/5 = 20%	80%
Falla 2	1/5 = 20%	80%
Falla 3	1/5 = 20%	80%
Falla 4	1/5 = 20%	80%
Falla 5	1/5 = 20%	80%

Para las probabilidades condicionadas de los estados de los nodos hijos, se debe determinar la probabilidad de que se presente cada estado de cada nodo hijo, ante la presencia de cada falla. Por ejemplo, debe determinarse la probabilidad de que para un nodo S1, se presente el estado “Normal”, si la falla F1 está presente. De la misma manera, debe determinarse la probabilidad de que el nodo S1 presente el estado “Bajo” ante la misma falla F1 y la probabilidad de que presente el estado “Alto” ante la misma falla F1. Así se puede configurar una tabla combinatoria en que se establecen todas las probabilidades de todos los estados de los nodos hijos ante la presencia de todos los estados de los nodos padre. Teniendo en cuenta que los nodos padre tienen dos estados (“Presente” y “No Presente”) y que los nodos hijos tienen tres estados (“Alto”, “Bajo”, “Normal”), el número de probabilidades a determinar está dado por la Ecuación 3-1

$$NP = (2^{NF} \times 3) \times NS \quad \text{Ecuación 3-1}$$

Donde NP es el número de probabilidades a determinar, NF es el número de nodos padre (Fallas) de la red, y NS es el número de nodos hijos (síntoma) de la red. Por ejemplo, si se tiene un sistema con tres (3) fallas conocidas y cuatro (4) variables síntoma, el número de probabilidades a determinar sería

$$NP = (2^{NF} \times 3) \times NS = (2^3 \times 3) \times 4 = 96$$

Estas probabilidades se pueden consignar en una plantilla como la mostrada en la Tabla 3-12.

Tabla 3-12. Plantilla general para las probabilidades condicionadas de los síntomas ante la combinación de fallas

Estados de las fallas				Estados de los síntomas y probabilidades asociadas			
	Falla F3	Falla F2	Falla F1	S1	Probabilidad	S2	Probabilidad
1	0	0	0	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
2	0	0	1	1	$P(S1=1 F3=0,F2=0,F1=1)$	1	$P(S2=1 F3=0,F2=0,F1=1)$
3	0	1	0	1	$P(S1=1 F3=0,F2=1,F1=0)$	1	$P(S2=1 F3=0,F2=1,F1=0)$
4	0	1	1	1	$P(S1=1 F3=0,F2=1,F1=1)$	1	$P(S2=1 F3=0,F2=1,F1=1)$
5	1	0	0	1	$P(S1=1 F3=1,F2=0,F1=0)$	1	$P(S2=1 F3=1,F2=0,F1=0)$
6	1	0	1	1	$P(S1=1 F3=1,F2=0,F1=1)$	1	$P(S2=1 F3=1,F2=0,F1=1)$
7	1	1	0	1	$P(S1=1 F3=1,F2=1,F1=0)$	1	$P(S2=1 F3=1,F2=1,F1=0)$
8	1	1	1	1	$P(S1=1 F3=1,F2=1,F1=1)$	1	$P(S2=1 F3=1,F2=1,F1=1)$
9	0	0	0	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
10	0	0	1	2	$P(S1=2 F3=0,F2=0,F1=1)$	2	$P(S2=2 F3=0,F2=0,F1=1)$
11	0	1	0	2	$P(S1=2 F3=0,F2=1,F1=0)$	2	$P(S2=2 F3=0,F2=1,F1=0)$
12	0	1	1	2	$P(S1=2 F3=0,F2=1,F1=1)$	2	$P(S2=2 F3=0,F2=1,F1=1)$
13	1	0	0	2	$P(S1=2 F3=1,F2=0,F1=0)$	2	$P(S2=2 F3=1,F2=0,F1=0)$
14	1	0	1	2	$P(S1=2 F3=1,F2=0,F1=1)$	2	$P(S2=2 F3=1,F2=0,F1=1)$
15	1	1	0	2	$P(S1=2 F3=1,F2=1,F1=0)$	2	$P(S2=2 F3=1,F2=1,F1=0)$
16	1	1	1	2	$P(S1=2 F3=1,F2=1,F1=1)$	2	$P(S2=2 F3=1,F2=1,F1=1)$
17	0	0	0	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$
18	0	0	1	3	$P(S1=3 F3=0,F2=0,F1=1)$	3	$P(S2=3 F3=0,F2=0,F1=1)$
19	0	1	0	3	$P(S1=3 F3=0,F2=1,F1=0)$	3	$P(S2=3 F3=0,F2=1,F1=0)$
20	0	1	1	3	$P(S1=3 F3=0,F2=1,F1=1)$	3	$P(S2=3 F3=0,F2=1,F1=1)$
21	1	0	0	3	$P(S1=3 F3=1,F2=0,F1=0)$	3	$P(S2=3 F3=1,F2=0,F1=0)$
22	1	0	1	3	$P(S1=3 F3=1,F2=0,F1=1)$	3	$P(S2=3 F3=1,F2=0,F1=1)$
23	1	1	0	3	$P(S1=3 F3=1,F2=1,F1=0)$	3	$P(S2=3 F3=1,F2=1,F1=0)$
24	1	1	1	3	$P(S1=3 F3=1,F2=1,F1=1)$	3	$P(S2=3 F3=1,F2=1,F1=1)$

En esta tabla, se han codificado los estados “Presente” y “No Presente” de las fallas, como 1 y 0 respectivamente. Los estados “Normal”, “Bajo” y “Alto” de los síntomas se han codificado como 1, 2 y 3 respectivamente. En cada fila se indica la combinación de las fallas de entrada y la probabilidad de que un síntoma asuma un estado dada la combinación de fallas. Por ejemplo, en la fila dos (2) sólo la falla F1 está “Presente”, y se determina la probabilidad de que el síntoma S1, esté en el estado “Normal” (es decir 1) dado que F1 está “Presente”, F2 está “No Presente” y F3 está “No Presente”, esto es $P(S1=1|F3=0,F2=0,F1=1)$. El mismo ejercicio se debe hacer para los síntomas S2, S3 y S4.

Para el alcance de este proyecto, se ha considerado que en todo momento solo una falla puede estar presente en el sistema productivo. Bajo esta premisa, no es necesario determinar todas las posibles combinaciones de la Tabla 3-12 y basta

con determinar sólo las probabilidades para las combinaciones en que hay una sola falla. Para las filas en que hay más de una falla presente, se puede asumir que ante la combinación de fallas, los síntomas estarán en estado normal. Con estas consideraciones, el número de probabilidades a determinar se puede reducir como se muestra en la Tabla 3-13.

Tabla 3-13. Plantilla general de probabilidades condicionadas de los síntomas considerando una sola falla presente

	Estados de las fallas			Estados de los síntomas y probabilidades asociadas			
	Falla F3	Falla F2	Falla F1	S1	Probabilidad	S2	Probabilidad
1	0	0	0	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
2	0	0	1	1	$P(S1=1 F3=0,F2=0,F1=1)$	1	$P(S2=1 F3=0,F2=0,F1=1)$
3	0	1	0	1	$P(S1=1 F3=0,F2=1,F1=0)$	1	$P(S2=1 F3=0,F2=1,F1=0)$
4	0	1	1	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
5	1	0	0	1	$P(S1=1 F3=1,F2=0,F1=0)$	1	$P(S2=1 F3=1,F2=0,F1=0)$
6	1	0	1	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
7	1	1	0	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
8	1	1	1	1	$P(S1=1 F3=0,F2=0,F1=0)$	1	$P(S2=1 F3=0,F2=0,F1=0)$
9	0	0	0	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
10	0	0	1	2	$P(S1=2 F3=0,F2=0,F1=1)$	2	$P(S2=2 F3=0,F2=0,F1=1)$
11	0	1	0	2	$P(S1=2 F3=0,F2=1,F1=0)$	2	$P(S2=2 F3=0,F2=1,F1=0)$
12	0	1	1	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
13	1	0	0	2	$P(S1=2 F3=1,F2=0,F1=0)$	2	$P(S2=2 F3=1,F2=0,F1=0)$
14	1	0	1	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
15	1	1	0	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
16	1	1	1	2	$P(S1=2 F3=0,F2=0,F1=0)$	2	$P(S2=2 F3=0,F2=0,F1=0)$
17	0	0	0	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$
18	0	0	1	3	$P(S1=3 F3=0,F2=0,F1=1)$	3	$P(S2=3 F3=0,F2=0,F1=1)$
19	0	1	0	3	$P(S1=3 F3=0,F2=1,F1=0)$	3	$P(S2=3 F3=0,F2=1,F1=0)$
20	0	1	1	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$
21	1	0	0	3	$P(S1=3 F3=1,F2=0,F1=0)$	3	$P(S2=3 F3=1,F2=0,F1=0)$
22	1	0	1	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$
23	1	1	0	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$
24	1	1	1	3	$P(S1=3 F3=0,F2=0,F1=0)$	3	$P(S2=3 F3=0,F2=0,F1=0)$

En la tabla se han resaltado las filas en las que efectivamente deben determinarse las probabilidades, considerando la presencia de una sola falla. Para las demás filas, se han remplazado las probabilidades por la probabilidad de que el síntoma asuma el estado indicado cuando todas las fallas tienen estado “No Presente”. Por ejemplo, para la fila cuatro (4) se tenía en la Tabla 3-12 para el síntoma S1, $P(S1=1|F3=0,F2=1,F2=1)$, ahora, en la Tabla 3-13 esta probabilidad se cambia por $P(S1=1|F3=0,F2=0,F2=0)$, que es la misma probabilidad determinada para la fila uno (1). En la fila veintidós (22), en la Tabla 3-12 se tenía para el síntoma S1, $P(S1=3|F3=1,F2=0,F1=1)$, ahora, en la Tabla 3-13 esta probabilidad se cambia por $P(S1=3|F3=0,F2=0,F1=0)$, que es la misma probabilidad determinada para la fila

veintiuno (21). De esta manera, el número real de probabilidades a determinar está dado por la Ecuación 3-2.

$$NP = [3 \times (NF + 1)] \times NS \quad \text{Ecuación 3-2}$$

Volviendo al sistema de ejemplo con tres fallas ($NF=3$) y cuatro síntomas ($NS=4$), donde la cantidad total de probabilidades, según la Ecuación 3-1, sería noventa y seis (96), se obtendría una reducción a cuarenta y ocho (48) probabilidades, al considerar que sólo puede estar presente una falla. Las cuarenta y ocho (48) probabilidades restantes se obtienen de las cuarenta y ocho (48) probabilidades determinadas, remplazando de acuerdo al ejemplo mostrado en la Tabla 3-13.

Ahora, para determinar el valor de estas probabilidades condicionadas se pueden revisar también los registros históricos del sistema productivo. El objetivo es determinar el estado que asume cada variable observada (síntoma) ante la presencia de cada falla. En primer lugar, se determina la probabilidad de cada estado de los síntomas cuando todas las fallas tienen estado “No Presente”, por ejemplo, para el síntoma $S1$, éstas serían $P(S1=1|F3=0, F2=0, F1=0)$, que es la probabilidad de que el síntoma $S1$ esté en estado “Normal”, dado que las fallas $F1$, $F2$ y $F3$ tienen estado “No Presente”, $P(S1=2|F3=0, F2=0, F1=0)$, que es la probabilidad de que el síntoma $S1$ esté en estado “Bajo”, dado que las fallas $F1$, $F2$ y $F3$ tienen estado “No Presente”, y $P(S1=3|F3=0, F2=0, F1=0)$, que es la probabilidad de que el síntoma $S1$ esté en estado “Alto” dado que las fallas $F1$, $F2$ y $F3$ tienen estado “No Presente”. Así, si se revisan cien (100) registros históricos del sistema productivo, y se determina que en esos registros no había falla presente, se podría contar cuantas veces el síntoma $S1$ asumió el estado “Normal”, cuantas veces asumió el estado “Bajo” y cuantas veces asumió el estado “Alto”. De esta manera, si el síntoma $S1$ estuvo “Normal” en 98 de los 100 registros, entonces $P(S1=1|F3=0, F2=0, F1=0) = 98\%$, si estuvo “Bajo” en 2 de los 100 registros, entonces $P(S1=2|F3=0, F2=0, F1=0) = 2\%$ y si no estuvo “Alto” en ningún caso, entonces $P(S1=3|F3=0, F2=0, F1=0) = 0\%$. En la Tabla 3-13 estas probabilidades corresponden a las probabilidades del síntoma $S1$ en las filas uno (1), nueve (9) y diecisiete (17). Observe que estas tres probabilidades suman 100%.

Luego, se deben ubicar en los registros, aquellos en que se tenga certeza de que la falla $F1$ estaba presente. Si se encuentran por ejemplo ochenta (80) registros en que la falla $F1$ estaba presente, se cuenta en estos ochenta (80) registros, cuantas veces el síntoma $S1$ estuvo en “Normal”, cuantas veces estuvo en “Bajo” y cuantas veces estuvo en “Alto”, esto determina la probabilidad $P(S1=1|F3=0, F2=0, F1=1)$, que es la probabilidad de que el síntoma $S1$ esté en estado “Normal” dado que la falla $F1$ está “Presente” y las fallas $F2$ y $F3$ están “No

Presente”, la probabilidad $P(S1=2|F3=0,F2=0,F1=1)$, que es la probabilidad de que el síntoma S1 esté en estado “Bajo” dado que la falla F1 tiene estado “Presente” y las fallas F2 y F3 tienen estado “No Presente”, y la probabilidad $P(S1=3|F3=0,F2=0,F1=1)$, que es la probabilidad de que el síntoma S1 esté en estado “Alto” dado que la falla F1 está en estado “Presente” y las fallas F2 y F3 están en estado “No Presente”. En la Tabla 3-13 estas probabilidades corresponden a las probabilidades para el síntoma S1 en las filas dos (2), diez (10) y dieciocho (18). Así, si el síntoma S1 estuvo “Normal” en siete (7) de los ochenta (80) registros $P(S1=1|F3=0,F2=0,F1=1)=8.75\%$, si estuvo “Bajo” en setenta (70) de los ochenta (80) registros, $P(S2=2|F3=0,F2=0,F1=1)=87.5\%$, y si estuvo “Alto” en tres (3) de los ochenta (80) registros, $P(S1=3|F3=0,F2=0,F1=1)=3.75\%$. Observe que estas tres probabilidades también suman 100%. En forma general se debe tener en cuenta que las tres probabilidades asociadas a los tres estados de cada síntoma frente a una falla determinada, siempre deben sumar 100%. Esto es $P(S1=1|C1)+P(S1=2|C1)+P(S1=3|C1)=100\%$, donde C1 es la combinación de los estados “Presente” y “No Presente” de las fallas. Para el ejemplo anterior, $C1=(F3=0,F2=0,F1=1)$.

El mismo ejercicio debe realizarse para todas las fallas conocidas del sistema. En la Tabla 3-14 se muestran ya ubicados los valores del ejercicio anterior y están vacías las probabilidades que faltan por determinarse.

Tabla 3-14. Valores del ejemplo para las probabilidades condicionadas

	Estados de las fallas			Estados de los síntomas y probabilidades asociadas			
	Falla F3	Falla F2	Falla F1	S1	Probabilidad	S2	Probabilidad
1	0	0	0	1	98%	1	
2	0	0	1	1	8.75%	1	
3	0	1	0	1		1	
4	0	1	1	1	98%	1	
5	1	0	0	1		1	
6	1	0	1	1	98%	1	
7	1	1	0	1	98%	1	
8	1	1	1	1	98%	1	
9	0	0	0	2	2%	2	
10	0	0	1	2	87.5%	2	
11	0	1	0	2		2	
12	0	1	1	2	2%	2	
13	1	0	0	2		2	
14	1	0	1	2	2%	2	
15	1	1	0	2	2%	2	
16	1	1	1	2	2%	2	
17	0	0	0	3	0%	3	
18	0	0	1	3	8.75%	3	
19	0	1	0	3		3	
20	0	1	1	3	0%	3	
21	1	0	0	3		3	

22	1	0	1	3	0%	3	
23	1	1	0	3	0%	3	
24	1	1	1	3	0%	3	

En algunos escenarios no se cuenta con los registros históricos del comportamiento del sistema productivo en presencia de las fallas y la aproximación presentada no es posible. En estos casos es posible utilizar la información consignada en la plantilla mostrada en la Tabla 3-6. A partir de la información contenida en esta plantilla, se puede asociar una probabilidad del 90% al estado normal de las variables síntoma ante las fallas específicas, y se distribuye el 10% restante de manera uniforme entre los otros dos estados. Volviendo al ejemplo del sistema productivo con tres (3) fallas y cuatro (4) síntomas, siguiendo el procedimiento presentado para la Tabla 3-6, se podrían obtener los estados habituales de cada síntoma ante cada falla, como se muestran en la Tabla 3-15

Tabla 3-15. Estados normales de los síntomas ante las fallas, indicados por los expertos

Falla Presente	Estados normales de los síntomas ante las fallas			
	S1	S2	S3	S4
No Falla	Normal	Normal	Normal	Normal
F1	Bajo	Alto	Normal	Normal
F2	Normal	Normal	Alto	Bajo
F3	Bajo	Normal	Bajo	Alto

Con esta información de los estados normales de los síntomas ante las fallas, se pueden determinar las probabilidades condicionadas, asociando un 90% de probabilidad al estado normal del síntoma ante la falla y 5% de probabilidad a cada uno de los otros dos estados ante la misma falla. Así, continuando con el ejemplo, cuando no hay falla presente, para el síntoma S1 se define que

$$P(S1=1|F3=0,F2=0,F1=0)=90\%$$

$$P(S1=2|F3=0,F2=0,F1=0)=5\%$$

$$P(S1=3|F3=0,F2=0,F1=0)=5\%$$

Esto indica que lo normal es que S1 esté “Normal” cuando no hay Falla. Para el síntoma S2 se define que

$$P(S2=1|F3=0,F2=0,F1=0)=90\%$$

$$P(S2=2|F3=0,F2=0,F1=0)=5\%$$

$$P(S2=3|F3=0,F2=0,F1=0)=5\%$$

Esto indica que lo normal es que S2 esté “Normal” cuando no hay falla. Para el síntoma S3 se define que

$$P(S3=1|F3=0,F2=0,F1=0)=90\%$$

$$P(S3=2|F3=0,F2=0,F1=0)=5\%$$

$$P(S3=3|F3=0,F2=0,F1=0)=5\%$$

Esto indica que lo normal es que S3 esté “Normal” cuando no hay falla. Y para el síntoma S4 se define que

$$P(S4=1|F3=0,F2=0,F1=0)=90\%$$

$$P(S4=2|F3=0,F2=0,F1=0)=5\%$$

$$P(S4=3|F3=0,F2=0,F1=0)=5\%$$

Esto indica que lo normal es que S4 esté “Normal” cuando no hay falla.

Ahora, cuando está presente la falla F1 se determina para S1 que

$$P(S1=1|F3=0,F2=0,F1=1)=5\%$$

$$P(S1=2|F3=0,F2=0,F1=1)=90\%$$

$$P(S1=3|F3=0,F2=0,F1=1)=5\%;$$

Esto indica que lo normal es que S1 esté “Bajo” cuando está presente la falla F1. Para S2 se determina que

$$P(S2=1|F3=0,F2=0,F1=1)=5\%$$

$$P(S2=2|F3=0,F2=0,F1=1)=5\%$$

$$P(S2=3|F3=0,F2=0,F1=1)=90\%$$

Esto indica que lo normal es que S2 esté “Alto” cuando está presente la falla F1. Para S3 se determina que

$$P(S3=1|F3=0,F2=0,F1=1)=90\%$$

$$P(S3=2|F3=0,F2=0,F1=1)=5\%$$

$$P(S3=3|F3=0,F2=0,F1=1)=5\%$$

Esto indica que lo normal es que S3 esté “Normal” cuando está presenta la falla F1. Y para S4 se determina que

$$P(S4=1|F3=0,F2=0,F1=1)=90\%$$

$$P(S4=2|F3=0,F2=0,F1=1)=5\%$$

$$P(S4=3|F3=0,F2=0,F1=1)=5\%$$

Esto indica que lo normal es que S4 esté “Normal” cuando está presente la falla F1.

Igualmente cuando se presenta la falla F2 se determina que para S1,

$$P(S1=1|F3=0,F2=1,F1=0)=90\%$$

$$P(S1=2|F3=0,F2=1,F1=0)=5\%$$

$$P(S1=3|F3=0,F2=1,F1=0)=5\%$$

Para S2

$$P(S2=1|F3=0,F2=1,F1=0)=90\%$$

$$P(S2=2|F3=0,F2=1,F1=0)=5\%$$

$$P(S2=3|F3=0,F2=1,F1=0)=5\%$$

Para S3

$$P(S3=1|F3=0,F2=1,F1=0)=5\%$$

$$P(S3=2|F3=0,F2=1,F1=0)=5\%$$

$$P(S3=3|F3=0,F2=1,F1=0)=90\%$$

Para S4

$$P(S4=1|F3=0,F2=1,F1=0)=5\%$$

$$P(S4=2|F3=0,F2=1,F1=0)=90\%$$

$$P(S4=3|F3=0,F2=1,F1=0)=5\%$$

Finalmente, cuando la falla F3 está presente se define que para S1

$$P(S1=1|F3=1,F2=0,F1=0)=5\%$$

$$P(S1=2|F3=1,F2=0,F1=0)=90\%$$

$$P(S1=3|F3=1,F2=0,F1=0)=5\%$$

Para S2

$$P(S2=1|F3=1,F2=0,F1=0)=90\%$$

$$P(S2=2|F3=1,F2=0,F1=0)=5\%$$

$$P(S2=3|F3=1,F2=0,F1=0)=5\%$$

Para S3

$$P(S3=1|F3=1,F2=0,F1=0)=5\%$$

$$P(S3=2|F3=1,F2=0,F1=0)=90\%$$

$$P(S3=3|F3=1,F2=0,F1=0)=5\%$$

Para S4

$$P(S4=1|F3=1,F2=0,F1=0)=5\%$$

$$P(S4=2|F3=1,F2=0,F1=0)=5\%$$

$$P(S4=3|F3=1,F2=0,F1=0)=90\%$$

Ahora, todas estas probabilidades se consignan en una plantilla como la mostrada en la Tabla 3-13. En la Tabla 3-16 se muestran estos valores registrados en la plantilla.

Tabla 3-16. Ejemplo probabilidades condicionadas a partir de estados normales en falla

	Estados de las fallas			Estados de los síntomas y probabilidades asociadas							
	Falla F3	Falla F2	Falla F1	S1	Prob.	S2	Prob.	S3	Prob.	S4	Prob.
1	0	0	0	1	90%	1	90%	1	90%	1	90%
2	0	0	1	1	5%	1	5%	1	90%	1	90%
3	0	1	0	1	90%	1	90%	1	5%	1	5%
4	0	1	1	1	90%	1	90%	1	90%	1	90%
5	1	0	0	1	5%	1	90%	1	5%	1	5%
6	1	0	1	1	90%	1	90%	1	90%	1	90%
7	1	1	0	1	90%	1	90%	1	90%	1	90%
8	1	1	1	1	90%	1	90%	1	90%	1	90%
9	0	0	0	2	5%	2	5%	2	5%	2	5%
10	0	0	1	2	90%	2	5%	2	5%	2	5%
11	0	1	0	2	5%	2	5%	2	5%	2	90%
12	0	1	1	2	5%	2	5%	2	5%	2	5%
13	1	0	0	2	90%	2	5%	2	90%	2	5%
14	1	0	1	2	5%	2	5%	2	5%	2	5%
15	1	1	0	2	5%	2	5%	2	5%	2	5%
16	1	1	1	2	5%	2	5%	2	5%	2	5%
17	0	0	0	3	5%	3	5%	3	5%	3	5%
18	0	0	1	3	5%	3	90%	3	5%	3	5%
19	0	1	0	3	5%	3	5%	3	90%	3	5%
20	0	1	1	3	5%	3	5%	3	5%	3	5%
21	1	0	0	3	5%	3	5%	3	5%	3	90%
22	1	0	1	3	5%	3	5%	3	5%	3	5%
23	1	1	0	3	5%	3	5%	3	5%	3	5%
24	1	1	1	3	5%	3	5%	3	5%	3	5%

Con esto quedan determinadas las probabilidades condicionadas de los síntomas a partir de lo que los expertos consideran los estados normales de las variables ante las fallas y finaliza el procedimiento de diseño del sistema de diagnóstico.

3.2. Desarrollo del sistema de diagnóstico cuando hay fallas con síntomas idénticos.

Durante el proceso de investigación se encontró que, de acuerdo a las variables escogidas para observación (síntomas), era posible que algunas fallas tuvieran síntomas idénticos. Por ejemplo, en la Figura 3-6 se observa un sistema para llenado y vaciado de un tanque donde la única variable observada es el nivel del tanque (LI1). En este sistema se pueden identificar tres fallas que podrían producir la misma sintomatología. Durante la operación de llenado, una obstrucción en la válvula de entrada V1, una fuga en el tanque o el mal funcionamiento de la válvula V2, son fallas cuyo efecto se observaría en el sensor de nivel LI1. Para estas tres

fallas, el sensor de nivel LI1 estaría arrojando un valor por debajo de lo normal de acuerdo al caudal de entrada para llenar el tanque.




Figura 3-6. Ejemplo falla con síntomas idénticos

Si bien la metodología propuesta puede funcionar en estos escenarios, se puede aprovechar la presencia de fallas con sintomatología idéntica para reducir el número de probabilidades a definir y por consiguiente se reduce la cantidad de cálculos y el peso computacional del sistema. Para lograr esto, se introducen dos pasos opcionales en el proceso de diseño, el primero es la identificación de fallas con sintomatología idéntica y el segundo es la agrupación de estas fallas. Para ilustrar la aplicación de estos dos pasos, a continuación se desarrolla un ejemplo en el que se realiza todo el procedimiento de diseño incluyendo la identificación y agrupación de fallas con sintomatología idéntica.

3.2.1. Delimitar el caso de estudio

Para este ejemplo, se considera un sistema productivo genérico donde se han identificado cuatro (4) fallas y cuatro (4) síntomas. Al delimitar el caso de estudio se obtienen las variables observadas del sistema, que se listan en la Tabla 3-17.

Tabla 3-17. Ejemplo síntomas idénticos. Variables del sistema

Tag	Descripción	Rango Normal	Anormalidad	
			Bajo	Alto
S1	Descripción variable s1	Valor normal s1	Valor bajo	Valor alto
S2	Descripción variable s2	Valor normal s2	Valor bajo	Valor alto
S3	Descripción variable s3	Valor normal s3	Valor bajo	Valor alto
S4	Descripción variable s4	Valor normal s4	Valor bajo	Valor alto

3.2.2. Definir el sistema observador

Dado que este es un ejemplo genérico, puede asumirse que se tiene un sistema observador con un modelo del sistema productivo, que monitorea todas las

variables y que arroja un vector de síntomas cuya forma general se muestra en la Tabla 3-18.

Tabla 3-18. Ejemplo síntomas idénticos. Vector de síntomas

Tiempo	Estados (Vector de Síntomas)			
	S1	S2	S3	S4
t	Estado de S1 en t	Estado de S2 en t	Estado de S3 en t	Estado de S4 en t

3.2.3. Listar las fallas conocidas

Para la construcción topológica se listan las fallas conocidas del sistema y se identifican los síntomas que afectan, como se muestra en la Tabla 3-19.

Tabla 3-19. Ejemplo síntomas idénticos. Tabla de fallas

Falla		Síntomas que afecta			
Tag	Descripción	S1	S2	S3	S4
F1	Descripción falla 1	No	Si	No	Si
F2	Descripción falla 2	Si	No	No	No
F3	Descripción falla 3	Si	No	No	No
F4	Descripción falla 4	No	No	Si	Si

En la tabla anterior solo interesa definir si una falla afecta o no un síntoma, y no de qué manera lo afecta.

3.2.4. Relacionar fallas y síntomas

En esta etapa debe definirse cómo afecta la presencia de cada falla a cada uno de los síntomas, teniendo en cuenta que cada síntoma puede asumir uno de tres valores, “Normal”, “Bajo” y “Alto”. En ese sentido es necesario identificar los estados normales de cada síntoma en presencia de cada falla, como se mostró en la Tabla 3-6 y la Tabla 3-15. Para este ejemplo, en la Tabla 3-20 se muestran los estados normales de los síntomas ante las fallas.

Tabla 3-20. Ejemplo síntomas idénticos. Estados normales de los síntomas ante las fallas conocidas

Falla Presente	Estados normales de los síntomas ante las fallas			
	S1	S2	S3	S4
No Falla	Normal	Normal	Normal	Normal
F1	Normal	Alto	Normal	Bajo
F2	Alto	Normal	Normal	Normal
F3	Alto	Normal	Normal	Normal
F4	Normal	Normal	Alto	Bajo

Al discretizar los valores alcanzados por los síntomas a los tres valores mostrados, Alto, Bajo y Normal, se facilita la identificación de síntomas iguales, ya que no se tienen en cuenta valores específicos de las variables. Note que en esta tabla se establece cómo se afectan los síntomas y no cuánto se afectan, esto significa, en el caso del síntoma S1, que lo que interesa es determinar que las fallas F2 y F3 llevan el síntoma S1 a su estado “Alto” y no interesa cuán alto lo lleva cada falla.

3.2.5. Identificar fallas con síntomas idénticos

Este es el primer paso en la reducción de la cantidad de probabilidades a determinar para el sistema de diagnóstico. Se parte de la observación de los valores mostrados en la Tabla 3-20, para identificar aquellas fallas que presentan sintomatología idéntica.

En la Tabla 3-20 se puede observar que las fallas F2 y F3 producen el mismo patrón de afectación en los síntomas. En esta tabla, ambas fallas hacen que el síntoma S1 esté en estado “Alto”, mientras que los demás síntomas permanecen en estado “Normal”. Por otro lado, observando la misma tabla, se determina que las fallas F1 y F4 tienen síntomas diferentes. De esta manera, se puede concluir que las fallas F2 y F3 son fallas que producen la misma sintomatología, mientras que las fallas F1 y F4 producen sintomatologías totalmente diferentes entre sí y diferentes del resto de fallas identificadas.

3.2.6. Agrupar fallas con síntomas idénticos

Habiendo identificado las fallas con afectación idéntica en los síntomas, se procede a generar agrupaciones de esas fallas. Para el ejemplo, se define un grupo G1 que agrupa las fallas F2 y F3. Este grupo G1 será un nodo adicional de la red, que funcionará como nodo padre de los síntomas y será nodo hijo de las fallas que agrupa. El conjunto de nodos grupo obtenido puede resumirse en una plantilla como las mostrada en la Tabla 3-21.

Tabla 3-21. Plantilla general para el listado de nodos de agrupación

Nodo Grupo	Fallas que agrupa	Estados asociados de las variables síntoma [S1 S2 S3 SK]
Gj	Fa, Fb, Fc... Fz	[Estado S1 Estado S2 Estado S3... Estado Sk]

En esta plantilla se identifican cuatro (4) campos:

- Nodo Grupo (Gj). Nombre que identifica al nodo grupo. Se sugiere usar el prefijo G y un numerador consecutivo para los grupos.

- Fallas que agrupa. Conjunto de fallas que presentan una misma sintomatología. Los valores de este campo corresponden a los nombres dados a las fallas en la lista de fallas conocidas, como la mostrada en la Tabla 3-3.
- Estados asociados de las variables síntoma. Corresponde al conjunto de valores específicos que normalmente asumen las variables síntomas ante el conjunto de fallas agrupado. En forma general, estos valores deben salir de la plantilla mostrada en la Tabla 3-6 y para este ejemplo específico se toman de la Tabla 3-20.

En la Tabla 3-22 se muestra el nodo de agrupación específico que se obtuvo para el ejemplo planteado.

Tabla 3-22. Ejemplo síntomas idénticos. Listado de nodos de agrupación

Nodo Grupo	Fallas que agrupa	Estados asociados de las variables síntoma [S1 S2 S3 S4]
G1	F2, F3	[Alto Normal Normal Normal]

3.2.7. Definir la topología

Al incluir en el procedimiento los pasos de agrupación de fallas con síntomas iguales, la topología de red planteada en la Figura 3-4, debe modificarse como se muestra en la Figura 3-7.




Figura 3-7. Ejemplo síntomas idénticos. Topología de red modificada

En la Figura 3-7, en el lado izquierdo, se muestra la topología originalmente planteada y en el lado derecho se muestra la topología teniendo en cuenta la agrupación de fallas con síntomas idénticos. En esta figura se resalta el nodo G1 en el que se hace la agrupación de las fallas F2 y F3. Se puede observar que ahora los síntomas no están directamente relacionados a todas las fallas y en lugar de ello se relacionan indirectamente con las fallas F2 y F3 a través del nodo G1 que sirve a modo de clúster.

3.2.8. Definir probabilidades

Definida la topología, se pasa a la construcción paramétrica, en la que se definen las probabilidades a priori de los nodos padres y las probabilidades condicionadas de los nodos hijos.

Para las probabilidades a priori y las probabilidades condicionadas se pueden seguir los procedimientos planteados en el apartado 3.1.6 *Definir probabilidades*, teniendo en cuenta que ahora existen nodos de agrupación.

Para las probabilidades a priori, asumiendo que se establecen probabilidades uniformes para las fallas, se obtendrían los valores que se muestran en la Tabla 3-23.

Tabla 3-23. Ejemplo síntomas idénticos. Probabilidades a priori

Falla	Probabilidad ocurrencia estado “Presente”	Probabilidad ocurrencia estado “No Presente”
Falla 1	$1/4 = 25\%$	75%
Falla 2	$1/4 = 25\%$	75%
Falla 3	$1/4 = 25\%$	75%
Falla 4	$1/4 = 25\%$	75%

Para las probabilidades de los nodos de agrupación, debe tenerse en cuenta que cada nodo grupo tiene dos estados posibles, “Presente” y “No Presente”, igual que los nodos de falla. Esto es porque la presencia de un nodo de agrupación, está directamente relacionada con la presencia de sus nodos padre, que son fallas. En otras palabras, un nodo grupo estará en estado “Presente” si al menos uno de sus nodos padre está en estado “Presente”. De esta manera, por cada nodo de agrupación debe construirse una plantilla como la mostrada en la Tabla 3-24.

En esta plantilla, se listan las posibles combinaciones de los estados de los nodos padre del nodo de agrupación, para el ejemplo, F1 y F2 son los nodos padre del nodo G1. Estos nodos padre, que son fallas, tienen dos estados posibles, “Presente”, codificado en la tabla anterior como “1” y “No Presente”, codificado como en la misma tabla como “0”. En cada fila, se establece la probabilidad de que el nodo grupo G1, tenga estado “Presente” dada la combinación de estados de sus nodos padre, y la probabilidad de que el nodo grupo G1 tenga estado “No Presente” dada la combinación de estados de sus nodos padre.

Tabla 3-24. Ejemplo síntomas idénticos. Probabilidades condicionadas del nodo grupo G1

	Fallas agrupadas por el nodo G1		Estados del nodo G1	Probabilidad
	F2	F1		
1	0	0	0	$P(G1=0 F1=0,F2=0)=90\%$
2	0	1	0	$P(G1=0 F1=1,F2=0)=10\%$
3	1	0	0	$P(G1=0 F1=0,F2=1)=10\%$
4	1	1	0	$P(G1=0 F1=1,F2=1)=10\%$
5	0	0	1	$P(G1=1 F1=0,F2=0)=10\%$
6	0	1	1	$P(G1=1 F1=1,F2=0)=90\%$
7	1	0	1	$P(G1=1 F1=0,F2=1)=90\%$
8	1	1	1	$P(G1=1 F1=1,F2=1)=90\%$

Para dar valor a estas probabilidades debe tenerse en cuenta que lo normal cuando no hay ninguna de las dos fallas presentes es que el nodo G1 tenga estado “No presente” y que lo normal, cuando hay al menos una de las dos fallas presente, es que el nodo G1 esté en estado “Presente”. Así, se asignan probabilidades de 90% a los estados normales ante la combinación de los estados de los nodos padre y 10% a los estados que no son normales ante la combinación de los estados de los nodos padre. Por ejemplo, en la fila uno (1), la combinación de los estados de las fallas es $F1=0$ y $F2=0$, es decir ambas fallas están en estado no presente, por lo que lo normal es que el nodo G1 esté en estado no presente, esto es $G1=0$, y por lo tanto $P(G1=0|F1=0,F2=0)=90\%$. Al mismo tiempo queda definida la probabilidad de la fila cinco (5), que sería complementaria a la probabilidad previamente definida, entonces $P(G1=1|F1=0,F2=0)=10\%$. Además, en las filas dos (2), tres (3) y cuatro (4), en las que al menos una de las fallas está presente, lo normal es que el nodo G1 esté en estado “Presente” y por lo tanto la probabilidad de que G1 esté en estado “No Presente” se asigna en 10% en cada una de estas filas. Finalmente, en las filas seis (6), siete (7) y ocho (8), se asigna un 90%, nuevamente teniendo en cuenta que si hay al menos una falla en estado “Presente”, lo normal sería que G1 esté en estado “Presente”.

El ejercicio realizado con el nodo G1, debe hacerse con todos los nodos que agrupen fallas en la topología de la red.

Para definir las probabilidades condicionadas de los nodos síntoma debe tenerse en cuenta que ahora los nodos de agrupación son nodos padre de los nodos síntomas. Así, la plantilla mostrada en la Tabla 3-13 se modificaría para excluir a los nodos que han sido agrupados, e incluir a los nodos de agrupación. Para este ejemplo, la plantilla quedaría como se muestra en la Tabla 3-25, donde se visualizan las probabilidades que deben determinarse para dos de las variables síntomas, S1 y S2.

El procedimiento para determinar el valor de estas probabilidades es el mismo que el descrito en el apartado 3.1.6 *Definir probabilidades*. Sin embargo, ya sea que las probabilidades se determinen a partir de los registros históricos o a partir del conocimiento de los expertos, se debe tener en cuenta que cuando se considera el estado “Presente” de un grupo de fallas, por ejemplo el grupo G1, se considera que al menos una de las fallas del grupo está en estado “Presente”. De la misma manera, cuando se considera que un grupo está en estado “No Presente”, se considera que todas las fallas del grupo están en estado “No Presente”. Esto significa que cuando se busca la presencia de un grupo de fallas en los registros históricos, o se consulta al experto por la presencia de este grupo de fallas, se debe buscar o preguntar si hay al menos una de las fallas que agrupa en estado “Presente”.

Tabla 3-25. Ejemplo síntomas idénticos. Probabilidades condicionadas de los síntomas

	Estados de las fallas			Estados de los síntomas y probabilidades asociadas			
	Falla F4	Grupo G1	Falla F1	S1	Probabilidad	S2	Probabilidad
1	0	0	0	1	$P(S1=1 F4=0,G1=0,F1=0)$	1	$P(S2=1 F4=0,G1=0,F1=0)$
2	0	0	1	1	$P(S1=1 F4=0,G1=0,F1=1)$	1	$P(S2=1 F4=0,G1=0,F1=1)$
3	0	1	0	1	$P(S1=1 F4=0,G1=1,F1=0)$	1	$P(S2=1 F4=0,G1=1,F1=0)$
4	0	1	1	1	$P(S1=1 F4=0,G1=1,F1=1)$	1	$P(S2=1 F4=0,G1=1,F1=1)$
5	1	0	0	1	$P(S1=1 F4=1,G1=0,F1=0)$	1	$P(S2=1 F4=1,G1=0,F1=0)$
6	1	0	1	1	$P(S1=1 F4=1,G1=0,F1=1)$	1	$P(S2=1 F4=1,G1=0,F1=1)$
7	1	1	0	1	$P(S1=1 F4=1,G1=1,F1=0)$	1	$P(S2=1 F4=1,G1=1,F1=0)$
8	1	1	1	1	$P(S1=1 F4=1,G1=1,F1=1)$	1	$P(S2=1 F4=1,G1=1,F1=1)$
9	0	0	0	2	$P(S1=2 F4=0,G1=0,F1=0)$	2	$P(S2=2 F4=0,G1=0,F1=0)$
10	0	0	1	2	$P(S1=2 F4=0,G1=0,F1=1)$	2	$P(S2=2 F4=0,G1=0,F1=1)$
11	0	1	0	2	$P(S1=2 F4=0,G1=1,F1=0)$	2	$P(S2=2 F4=0,G1=1,F1=0)$
12	0	1	1	2	$P(S1=2 F4=0,G1=1,F1=1)$	2	$P(S2=2 F4=0,G1=1,F1=1)$
13	1	0	0	2	$P(S1=2 F4=1,G1=0,F1=0)$	2	$P(S2=2 F4=1,G1=0,F1=0)$
14	1	0	1	2	$P(S1=2 F4=1,G1=0,F1=1)$	2	$P(S2=2 F4=1,G1=0,F1=1)$
15	1	1	0	2	$P(S1=2 F4=1,G1=1,F1=0)$	2	$P(S2=2 F4=1,G1=1,F1=0)$
16	1	1	1	2	$P(S1=2 F4=1,G1=1,F1=1)$	2	$P(S2=2 F4=1,G1=1,F1=1)$
17	0	0	0	3	$P(S1=3 F4=0,G1=0,F1=0)$	3	$P(S2=3 F4=0,G1=0,F1=0)$
18	0	0	1	3	$P(S1=3 F4=0,G1=0,F1=1)$	3	$P(S2=3 F4=0,G1=0,F1=1)$
19	0	1	0	3	$P(S1=3 F4=0,G1=1,F1=0)$	3	$P(S2=3 F4=0,G1=1,F1=0)$
20	0	1	1	3	$P(S1=3 F4=0,G1=1,F1=1)$	3	$P(S2=3 F4=0,G1=1,F1=1)$
21	1	0	0	3	$P(S1=3 F4=1,G1=0,F1=0)$	3	$P(S2=3 F4=1,G1=0,F1=0)$
22	1	0	1	3	$P(S1=3 F4=1,G1=0,F1=1)$	3	$P(S2=3 F4=1,G1=0,F1=1)$
23	1	1	0	3	$P(S1=3 F4=1,G1=1,F1=0)$	3	$P(S2=3 F4=1,G1=1,F1=0)$
24	1	1	1	3	$P(S1=3 F4=1,G1=1,F1=1)$	3	$P(S2=3 F4=1,G1=1,F1=1)$

Al considerar la agrupación de fallas con sintomatología idéntica, se reduce el costo computacional del sistema. En el ejemplo presentado, si no se hiciera la agrupación de fallas, de acuerdo a la Ecuación 3-1, se tendría

$$NP = (2^{NF} \times 3) \times NS = (2^4 \times 3) \times 4 = 192$$

Esto es, ciento noventa y dos (192) probabilidades condicionadas. Considerando la agrupación de fallas con síntomas idénticos, el número de probabilidades condicionadas a determinar está dado por

$$NP = \left[\sum_{j=1}^N (2^{NF_j}) \times 2 \right] + (2^{(NFI+NG)} \times 3) \times NS \quad \text{Ecuación 3-3}$$

Donde N es el número de nodos que hacen agrupación de fallas, es decir, la cantidad de nodos de agrupación, NF_j es el número de fallas que agrupa el j -ésimo nodo de agrupación, NFI es el número de fallas independientes, es decir que no están agrupadas en ningún nodo, NG es el número de nodos de agrupación y NS es el número de nodos síntoma. Para el ejemplo anterior, donde hay cuatro (4) fallas, cuatro (4) síntomas y un (1) nodo de agrupación que agrupa dos (2) fallas, se tendría

$$NP = [(2^2) \times 2] + (2^{(2+1)} \times 3) \times 4 = 104$$

Lo que da un total de ciento cuatro (104) probabilidades, en lugar de las ciento noventa y dos (192) originales.

Con esto quedan determinadas las probabilidades condicionadas de los síntomas, las probabilidades condicionadas de los nodos de agrupación y las probabilidades a priori de los nodos de falla, finalizando el procedimiento de diseño del sistema de diagnóstico.

3.3. Sistema de Diagnóstico. Tabla de diagnóstico

El procedimiento planteado en las secciones anteriores arroja como resultado un sistema de diagnóstico. Ya sea que se haga o no la reducción de fallas con síntomas iguales, el sistema de diagnóstico obtenido en ambos casos es conceptualmente el mismo y los resultados entregados serán similares en ambos casos.

De acuerdo al esquema planteado en la Figura 3-1, Este sistema de diagnóstico comprende el bloque OBSERVADOR que recibirá el conjunto de señales de sensores, actuadores y configuraciones del sistema productivo, producirá un vector de síntomas que alimentarán el bloque de DIAGNÓSTICO y este arrojará el diagnóstico apropiado dado el vector de síntomas. Este diagnóstico está planteado como una tabla en que se asocia la probabilidad de que la configuración de los estados indicados en el vector de síntomas recibido corresponda con la presencia de alguna de las fallas especificadas del sistema. En la

Tabla 3-26 se muestra la forma general para esta plantilla.

Tabla 3-26. Plantilla general diagnóstico generado

Vector de Síntomas = [Estado S1 - Estado S2 – Estado Sk]	
Falla	Probabilidad
F1	Probabilidad de que F1 esté en estado “Presente” con el vector de síntomas dado
F2	Probabilidad de que F2 esté en estado “Presente” con el vector de síntomas dado
Fn	Probabilidad de que Fn esté en estado “Presente” con el vector de síntomas dado

Para un sistema con un conjunto de fallas y síntomas como el que se presenta en la Tabla 3-15, una tabla de diagnóstico arrojada por el sistema podría ser como la presentada en la Tabla 3-27.

Tabla 3-27. Ejemplo de diagnóstico generado por el sistema

Vector de Síntomas = [Normal Normal Alto Bajo]	
Falla	Probabilidad
F1	16%
F2	75%
F3	8%

En esta tabla, el vector de síntomas arrojado por el bloque OBSERVADOR es [Normal Normal Alto Bajo], y tiene un 75% de probabilidad de corresponder con la presencia de la falla F2, 16% de probabilidad de corresponder con la presencia de la falla F1 y 8% de probabilidad de corresponder con la presencia de la falla F3. Con esta información, los operarios pueden enfocar sus esfuerzos en la falla F2 sin perder tiempo evaluando el resto de posibles fallas del sistema productivo.

3.4. Validación del sistema de Diagnóstico

Una vez se obtiene la red Bayesiana, se puede hacer un primer procedimiento de validación utilizando herramientas de simulación. Se sugiere hacer este procedimiento en dos pasos. En primer lugar, verificar el correcto funcionamiento del bloque observador y luego verificar el funcionamiento del bloque de diagnóstico, asegurando que los diagnósticos para los distintos vectores de síntomas sean adecuados.

Para verificar el comportamiento del bloque observador, se puede alimentar este bloque con el estado de todas las variables observadas del sistema productivo y mediante el conocimiento de los operarios, verificar si el vector de síntomas es coherente con el estado del sistema. Dado que difícilmente se pueden inducir fallas en el sistema productivo real, se hace complejo determinar inicialmente el comportamiento del bloque observador ante la presencia de las fallas. Por ello, se sugiere en primera instancia corroborar que al menos durante el funcionamiento normal del sistema productivo, el vector de síntomas arrojado por el bloque observador, tenga todas las variables síntoma en estado “Normal”. Si hay errores en el sistema observador se pueden corregir en etapas posteriores ajustando los modelos definidos para determinar el estado ideal del sistema productivo.

Para verificar el comportamiento del bloque de diagnóstico, se pueden simular cada uno de los vectores de síntomas y corroborar que las probabilidades arrojadas en la tabla de diagnóstico sean coherentes.

3.5. Afinación del sistema de diagnóstico

Durante la puesta en marcha del sistema de diagnóstico, debe observarse el diagnóstico generado y evaluar si es necesario hacer ajustes que permitan mejorar la confiabilidad. En la Figura 3-2, donde se muestra el procedimiento de diseño, se han identificado también tres elementos que son susceptibles de afinar para mejorar el desempeño.

- Ajuste de probabilidades. El ajuste de probabilidades es una tarea que se puede realizar en cualquier momento sin tener que cambiar la topología de la red. Esto permite ajustar los parámetros y mejorar la calidad del diagnóstico. Son susceptibles de ajustar las probabilidades a priori de las fallas y las probabilidades condicionadas de los nodos hijos.

Una vez el sistema entre en funcionamiento, un cambio en un equipo, maquinaria o sensor del sistema productivo podría generar también la necesidad del ajuste de las probabilidades a priori. En ese sentido, se podría considerar por ejemplo que un sistema productivo con un equipo A que lleva X tiempo en servicio, con una falla FA, específicamente asociada a dicho equipo, podría requerir ajuste en sus probabilidades a priori de falla si el equipo A es cambiado por uno más confiable, o si se hacen tareas de mantenimiento al mismo equipo, y se mejora su confiabilidad. También, la mitigación de factores externos al sistema productivo (condiciones ambientales por ejemplo) que promueven las fallas, o la corrección de factores internos (suciedad, desajuste, calentamiento) podrían requerir el ajuste de estas probabilidades.

- Inclusión de nuevas fallas. Durante el diseño del sistema de diagnóstico es posible que se pasen por alto algunas fallas del sistema y que no queden especificadas dentro del listado de fallas. Durante el funcionamiento del sistema de diagnóstico se obtendrá un diagnóstico errado ya que la falla no está incluida en el sistema. En ese caso, el operario debe discernir y determinar que es necesario incluir la falla en el sistema de diagnóstico. Con esto, se hace necesario retomar el proceso de diseño desde la generación del listado de fallas conocidas, completar las tablas de afectación de la nueva falla hacia los síntomas y obtener nuevamente las probabilidades.
- Inclusión de nuevos síntomas. La inclusión de nuevos síntomas permite hacer una diferenciación más precisa de las fallas. Sin embargo se sugiere que sólo se considere hacer esta inclusión si la sintomatología planteada inicialmente no permite diferenciar las fallas entre sí. Esta recomendación se fundamenta en el hecho que cada síntoma hace crecer exponencialmente el número de probabilidades condicionadas a determinar (ver Ecuación 3-1 y Ecuación 3-3) y por consiguiente hace el sistema de diagnóstico computacionalmente más costoso.

El procedimiento de afinación debe hacerse una vez el sistema se ponga en marcha. Dado el alcance de este proyecto, esta etapa se deja planteada para trabajos posteriores.

3.6. Resumen del capítulo

Se ha presentado una propuesta genérica, con pasos concretos para diseñar un sistema de detección y diagnóstico de fallas en sistemas productivos. La propuesta se enfoca en mantener sencillo el procedimiento de diseño del sistema de diagnóstico, utilizando la topología de red Bayesiana más simple posible y un conjunto de probabilidades que si bien son relativamente cuantiosas, son también relativamente fáciles de determinar.

4. CASOS DE ESTUDIO

En este capítulo se ponen en práctica los pasos listados en la propuesta para el diseño de sistemas de detección y diagnóstico de fallas. El objetivo es corroborar la viabilidad del procedimiento propuesto tomando como ejemplo dos casos de estudio que comprenden sistemas productivos totalmente diferentes. El primero es un proceso de preparación de crema desodorante donde se busca garantizar la confiabilidad del proceso para obtener un producto que supere los controles de calidad y reducir así las pérdidas por desecho de material. El segundo es un proceso de potabilización de agua, en el que se busca tener alertas tempranas respecto del funcionamiento del sistema productivo, ya que éste abastece un porcentaje importante de una comunidad y el desperdicio del agua o la mala calidad en la misma, son situaciones que deben evitarse al máximo.

4.1. Caso estudio 1. Preparación de crema desodorante.

En este caso de estudio se propone un sistema productivo perteneciente a la industria de producción de elementos de aseo personal de la región sur occidente del país, específicamente el sistema de producción de crema desodorante. El inadecuado funcionamiento de este sistema productivo podría generar mala calidad en el producto final, lo que conlleva al desecho del mismo y las correspondientes pérdidas económicas que esto significa para la compañía productora.

La preparación de la crema de desodorante consta de tres (3) etapas principales, Preparación de la fase acuosa, Preparación de la fase oleosa y mezcla de las dos fases. En la Figura 4-1 se muestra el diagrama general de este proceso. En dicha figura se puede observar que el proceso consta de dos tanques, el tanque pre-calentador donde se prepara la fase acuosa, y el tanque reactor donde se prepara la fase oleosa, y se mezcla con la fase acuosa para obtener el producto final.

En el tanque pre-calentador se mezclan perfumes (alcoholes) y antioxidantes en forma líquida para obtener la fase acuosa. Para esto, se adicionan los componentes al tanque, se mezclan y se calientan por veinte (20) minutos. Paralelamente, en el tanque reactor se mezclan clorhidratos y alcoholes en forma sólida para obtener la fase oleosa. Al estar lista la fase acuosa, ésta es descargada al reactor a una presión de 80 PSI y una temperatura de 85°C, para mezclarse con la fase oleosa durante treinta y cinco (35) minutos. Una vez finalizada la mezcla, que ahora es crema desodorante, se descarga a los tanques de almacenamiento para su posterior proceso de empaque.

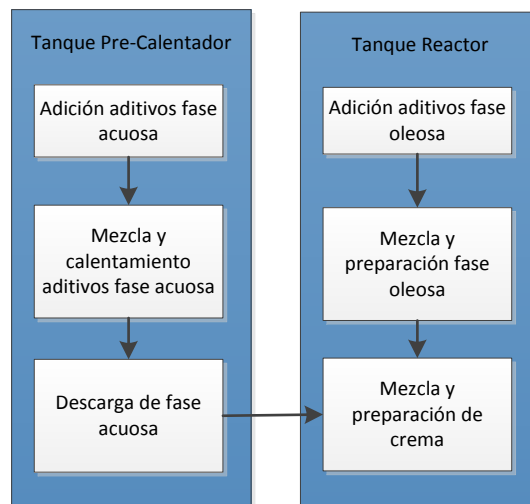


Figura 4-1. Diagrama proceso preparación de crema desodorante

La Figura 4-2 muestra como es la adecuación de los equipos y complementos del proceso. En la figura se observan los dos tanques del sistema, el tanque pre-calentador y el tanque reactor.




Figura 4-2. Sistema de pre-calentador-Reactor en cascada

El tanque de precalentamiento, en donde se realiza la mezcla de la fase acuosa, está conformado por un intercambiador de calor (Heat Exchanger), una electroválvula (V1) que se encarga de la descarga de los alcoholes y

antioxidantes, un sensor de temperatura (TI1) con el que se regula el funcionamiento del intercambiador de calor, y un sensor de nivel (LI1) que regula el funcionamiento de la electroválvula V1.

En el tanque reactor se tienen las electroválvulas V2 y V3, cada una gobernada por un sensor de flujo FI1 y FI2, respectivamente. A través de la electroválvula V2 se controla el paso de la fase acuosa, mientras que la electroválvula V3 controla el flujo de descarga de los aditivos de la fase oleosa. Además, este tanque cuenta con sensor de temperatura (TI2) que gobierna el paso de vapor a la chaqueta del reactor y un sensor que indica la cantidad de mezcla (QI1) presente en el tanque.

El proceso empieza activando la electroválvula V3 para descargar al tanque reactor los aditivos de la fase oleosa, a una rata de 0.032 m³/min. En el tanque reactor empieza un proceso de agitación a una presión de 60 PSI durante un tiempo de 25 minutos. Simultáneamente se activa la válvula V1 para descargar al tanque pre-calentador los aditivos de la fase acuosa, a una rata de 0.0245m³/min. Al tener el nivel adecuado en el tanque pre-calentador, se activa un agitador para mezclar y se calienta a través del intercambiador de calor, por un periodo de 20 minutos, hasta tener la fase acuosa a una temperatura de 45°C. Con la fase acuosa lista, se activa la electroválvula V2, permitiendo su paso al tanque reactor, controlando el flujo a través del sensor FI1, con el fin de garantizar una descarga suave y continua sobre el reactor, evitando así la generación de burbujas de vacío. Cuando se tiene el nivel adecuado en el tanque reactor, se eleva la temperatura en la chaqueta a 85°C con una presión de 80 PSI, para iniciar el ciclo de mezcla y la reacción química entre las dos fases. Esta mezcla en el reactor toma alrededor de 35 minutos para la generación de la crema desodorante. Posteriormente es descargada a los tanques de almacenamiento.

4.1.1. Caso estudio 1. Delimitar el caso de estudio

En la Tabla 4-1 se listaron las variables observables del proceso. En esta tabla se tienen las variables de las que se conoce un valor cuantitativo en todo momento y fueron extraídas de los documentos de instrumentación y del conocimiento de los operarios. Se muestran en la tabla también los rangos normales de operación, y los estados bajos y altos de cada una.

Tabla 4-1. Caso estudio 1. Variables del sistema

Tag	Descripción	Rango Normal	Anormalidad	
			Bajo	Alto
S1TI1	Temperatura pre-calentador	40°C	38°C	42°C
S2LI1	Nivel en pre-calentador.	0,6m	0,55m	0,65m
S3FI1	Flujo salida V2	0,052 m ³ /s	0,05 m ³ /s	0,054 m ³ /s
S4TI2	Temperatura reactor	60°C	59,5 °C	60,5 °C
S5QI1	Cantidad de mezcla en el reactor	63%	62,98%	63,02%
S6FI2	Flujo salida V3	0,03 m ³ /s	0,025 m ³ /s	0,035 m ³ /s

4.1.2. Caso estudio 1. Definir el sistema observador

Para este caso de estudio, se define a un operario experto como el sistema observador. La labor del operario experto es observar el estado de las variables del sistema, y de acuerdo a su experticia definir si las variables se encuentran en estado normal, alto o bajo. Esta información es la que debe alimentar al bloque de diagnóstico, donde cada una de las variables observadas es un síntoma. Normalmente, los operarios expertos tienen en su base de conocimiento un conjunto de reglas bajo las cuales toman las decisiones. El operario experto debe definir la frecuencia con que se observan las variables del proceso y consignar el estado de cada variable en la tabla del vector de síntomas. En este caso, el experto definió que las variables deben observarse cada minuto, y los valores se irán consignando en la Tabla 4-2.

Tabla 4-2. Caso estudio 1. Tabla con vectores de síntomas

Tiempo	Estados (Vector de Síntomas)					
	S1TI1	S2LI1	S3FI2	S4TI2	S5QI1	S6FI3
0	Normal	Normal	Normal	Normal	Normal	Normal

4.1.3. Caso estudio 1. Listar las fallas conocidas

Para la construcción topológica se listan las fallas conocidas del sistema y se identifican los síntomas que afectan, como se muestra en la Tabla 4-3. Este listado de fallas fue obtenido con la ayuda de los expertos.

Tabla 4-3. Caso estudio 1. Listado de fallas conocidas

Falla		Síntomas que afecta					
Tag	Descripción	S1TI1	S2LI1	S3FI2	S4TI2	S5QI1	S6FI3
F1	Válvula 1 atascada, cerrada.	No	Si	No	No	No	No
F2	Válvula 2 atascada, cerrada.	No	Si	Si	Si	Si	No
F3	Válvula 3 atascada, cerrada.	No	No	No	Si	Si	Si
F4	Válvula 1 atascada, abierta.	No	Si	No	No	No	No
F5	Válvula 2 atascada, abierta.	No	Si	Si	Si	Si	No
F6	Válvula 3 atascada, abierta.	No	No	No	Si	Si	Si
F7	Intercambiador de calor malo.	Si	No	No	Si	No	No
F8	Falta de vapor en chaqueta.	No	No	No	Si	No	No
F9	Fuga en el tanque con chaqueta.	No	No	No	Si	No	No

En la tabla se describe cada una de las fallas y se muestra los síntomas que se afectan en presencia de cada falla. Por ejemplo, la presencia de la falla F1 afecta el síntoma S1LI1, mientras que la presencia de la falla F5 afecta los síntomas S2LI1, S3FI2, S4TI2 y S5QI1. Se puede observar que en la tabla sólo interesa especificar que síntomas se afectan y no de qué manera se afectan.

4.1.4. Caso estudio 1. Relacionar fallas y síntomas

En esta etapa debe definirse cómo afecta la presencia de cada falla a cada uno de los síntomas, teniendo en cuenta que cada síntoma puede asumir uno de tres valores, “Normal (N)”, “Bajo (B)” y “Alto (A)”. Para ello, se consultó con los expertos cuáles eran los estados normales de los síntomas en presencia de las fallas. Los resultados se resumen en la Tabla 4-4.

Tabla 4-4. Caso estudio 1. Estados normales de los síntomas ante las fallas

	S1TI1	S2LI1	S3FI2	S4TI2	S5QI1	S6FI3
F1	N	B	N	N	N	N
F2	N	A	B	B	B	N
F3	N	N	N	B	A	B
F4	N	A	N	N	N	N
F5	N	B	A	A	A	N
F6	N	N	N	A	B	A
F7	B	N	N	B	N	N
F8	N	N	N	B	N	N
F9	N	N	N	B	N	N

En la tabla anterior se puede observar que las fallas F8 y F9 tienen sintomatología idéntica. En este punto se podría aplicar la reducción de fallas, pero por ahora se seguirá el procedimiento sin estos pasos y más adelante se hará la comparación con el procedimiento reduciendo fallas que tienen iguales síntomas.

4.1.5. Caso estudio 1. Definir la topología

La Figura 4-3 muestra la topología de la red bayesiana de diagnóstico del caso de estudio, construida a partir de la red Naive Bayes.




Figura 4-3. Caso de estudio 1. Red Naive Bayes de diagnóstico.

Como se puede observar en esta red, todos los nodos padre están relacionados con todos los nodos hijos.

4.1.6. Caso estudio 1. Definir probabilidades

Para la determinación de las probabilidades a priori, en este ejemplo se utilizó la distribución uniforme para validar la viabilidad de esta aproximación. En ese sentido, todas las fallas conocidas tienen la misma probabilidad de ocurrencia, que es 11%. Una vez el sistema entre en funcionamiento, estas probabilidades se pueden ajustar de acuerdo a la frecuencia con que vayan apareciendo las fallas.

Tabla 4-5. Caso estudio 1. Probabilidades a priori

Falla	Probabilidad Ocurrencia	Probabilidad No Ocurrencia
F1	$1/9 = 0,11 \rightarrow 11\%$	89%
F2	$1/9 = 0,11 \rightarrow 11\%$	89%
F3	$1/9 = 0,11 \rightarrow 11\%$	89%
F4	$1/9 = 0,11 \rightarrow 11\%$	89%
F5	$1/9 = 0,11 \rightarrow 11\%$	89%
F6	$1/9 = 0,11 \rightarrow 11\%$	89%
F7	$1/9 = 0,11 \rightarrow 11\%$	89%
F8	$1/9 = 0,11 \rightarrow 11\%$	89%
F9	$1/9 = 0,11 \rightarrow 11\%$	89%

Para obtener las tablas de probabilidad condicionada fue necesario simular el sistema ante la presencia de cada falla conocida. Esto debido a que no se cuenta con registros históricos del estado de los sensores en presencia de las fallas y tampoco se pueden inducir las fallas en el sistema real.

Durante la simulación del proceso de estudio frente a los diferentes eventos de fallas, se capturaron las mediciones por parte de los sensores, se discretizó a estados de normal, bajo y alto, y se determinó la frecuencia de ocurrencia de cada estado ante cada falla; de esta manera se halló las tablas de probabilidades condicionadas para cada una de los nodos síntomas. En la Tabla 4-6 se muestran las probabilidades condicionadas para los síntomas (variables) S1TI1, S2LI1 y S3FI2, en presencia de cada una de las fallas.

Tabla 4-6. Caso estudio 1. Tablas de probabilidad condicionada síntomas S1TI1, S2LI1 y S3FI2

Falla	S1TI1			S2LI1			S3FI2		
	N	B	A	N	B	A	N	B	A
F1	68,0%	16,5%	15,5%	18,5%	65,0%	16,5%	73,0%	16,0%	11,0%
F2	66,0%	17,5%	16,5%	20,0%	16,5%	63,5%	16,5%	70,0%	13,5%
F3	65,5%	20,5%	14,0%	67,0%	14,5%	18,5%	61,5%	18,5%	20,0%
F4	67,5%	14,0%	18,5%	10,0%	18,5%	71,5%	71,5%	12,0%	16,5%
F5	67,5%	18,0%	14,5%	18,0%	61,5%	20,5%	13,0%	13,5%	73,5%
F6	69,5%	16,0%	14,5%	66,0%	17,5%	16,5%	71,5%	14,0%	14,5%
F7	19,5%	64,5%	16,0%	65,5%	13,5%	21,0%	67,5%	16,0%	16,5%
F8	67,0%	16,0%	17,0%	67,5%	16,5%	16,0%	62,5%	18,0%	19,5%
F9	73,0%	12,5%	14,5%	73,0%	13,5%	13,5%	64,0%	19,0%	17,0%

En la tabla anterior se puede observar que el síntoma S1TI1 tiende a estar en estados normales ante la presencia del 88,8% de las fallas, esto es, está en estados normales ante ocho de las nueve fallas conocidas, y presenta un estado bajo ante una de las nueve fallas, que es la falla F7. El síntoma S2LI1 tiende a presentar estados normales en las fallas F3, F6, F7, F8 y F9, lo que corresponde al 55,5%, mientras que presenta tendencia a estar en estado bajo en las fallas F1 y F5, y estado alto en las fallas F2 y F4. El síntoma S3FI2 tiende a presentar estado bajo en la falla F2, estado alto en la falla F5 y estados normales en el resto de las fallas.

El mismo ejercicio se realizó con los síntomas S4TI2, S5QI1 y S6FI3. Los resultados se muestran en la Tabla 4-7.

Tabla 4-7. Caso estudio 1. Tablas de probabilidad condicionada síntomas S4, S5 y S6.

	S4TI2			S5QI1			S6FI3		
	N	B	A	N	B	A	N	B	A
F1	68,5%	15,5%	16,0%	65,0%	17,0%	18,0%	67,0%	20,0%	13,0%
F2	17,5%	65,0%	17,5%	17,0%	65,5%	17,5%	72,0%	15,5%	12,5%
F3	17,5%	69,5%	13,0%	15,5%	14,5%	70,0%	17,0%	64,0%	19,0%
F4	69,0%	16,5%	14,5%	72,0%	12,0%	16,0%	65,0%	22,0%	13,0%
F5	23,5%	15,5%	61,0%	16,0%	18,5%	65,5%	68,0%	13,0%	19,0%
F6	14,5%	17,5%	68,0%	12,0%	68,5%	19,5%	16,0%	19,5%	64,5%
F7	18,0%	64,5%	17,5%	64,5%	18,0%	17,5%	66,0%	16,5%	17,5%
F8	16,0%	66,5%	17,5%	66,5%	12,0%	21,5%	72,0%	12,5%	15,5%
F9	17,0%	72,0%	11,0%	75,5%	11,5%	13,0%	69,0%	16,5%	14,5%

Note que las tablas de probabilidad condicionada mostradas contienen sólo las probabilidades condicionadas considerando la presencia de una sola falla. A partir de estas probabilidades se debe llenar una plantilla como la mostrada en la Tabla 3-13, para así obtener la tabla completa con que el sistema debe hacer la inferencia. En la Tabla 4-8 se muestra el encabezado de la plantilla y las primeras cinco (5) probabilidades para el síntoma S1T1. Por cuestiones de espacio no se pone la tabla completa, ya que de acuerdo a la Ecuación 3-1, el número de probabilidades de esta tabla está dado por

$$NP = (2^{NF} \times 3) \times NS = (2^9 \times 3) \times 6 = 9216$$

Esto es 9216 probabilidades, distribuidas en $(2^{NF} \times 3) = (2^9 \times 3) = 1536$ filas. Si bien esta tabla es extensa, fácilmente se puede escribir un script que la genere, ya que la mayoría de las filas corresponden a combinación de fallas, que como se mencionó en secciones anteriores, tienen asignada la misma probabilidad que aquellas filas en que no hay fallas.

Tabla 4-8. Caso estudio 1. Tabla completa de probabilidades condicionadas

Estados de las fallas										Estados de los síntomas y probabilidades asociadas	
	F9	F8	F7	F6	F5	F4	F3	F2	F1	S1T1	Probabilidad
1	0	0	0	0	0	0	0	0	0	1	$P(S1=1 F9=0,F8=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=0)$
2	0	0	0	0	0	0	0	0	1	1	$P(S1=1 F9=0,F8=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=1)$
3	0	0	0	0	0	0	0	1	0	1	$P(S1=1 F9=0,F8=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=1,F1=0)$
4	0	0	0	0	0	0	0	1	1	1	$P(S1=1 F9=0,F8=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=0)$
5	0	0	0	0	0	0	1	0	0	1	$P(S1=1 F9=0,F8=0,F7=0,F6=0,F5=0,F4=0,F3=1,F2=0,F1=0)$

Por otro lado, para efectos de comparación, se propone determinar las probabilidades condicionadas, utilizando la aproximación mostrada en la Tabla 3-15 y Tabla 3-16, donde se definen las probabilidades condicionadas a partir de lo que los expertos consideran los estados normales de los síntomas en presencia de las fallas. Para ello, se usan como base los estados normales de los síntomas ante las fallas, que se muestran en la Tabla 4-4. A partir de esta tabla de estados normales, se definen las probabilidades condicionadas, asociando una probabilidad del 90% al estado que normalmente se presenta ante la falla, y distribuyendo de manera uniforme el 10% restante entre los otros dos estados. En la Tabla 4-9 se muestran las probabilidades asignadas.

Tabla 4-9. Caso estudio 1. Probabilidades condicionadas a partir de estados normales en falla

	S1TI1			S2LI1			S3FI2		
	N	B	A	N	B	A	N	B	A
F1	90,0%	5,0%	5,0%	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%
F2	90,0%	5,0%	5,0%	5,0%	5,0%	90,0%	5,0%	90,0%	5,0%
F3	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F4	90,0%	5,0%	5,0%	5,0%	5,0%	90,0%	90,0%	5,0%	5,0%
F5	90,0%	5,0%	5,0%	5,0%	90,0%	5,0%	5,0%	5,0%	90,0%
F6	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F7	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F8	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F9	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
	S4TI2			S5QI1			S6FI3		
	N	B	A	N	B	A	N	B	A
F1	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F2	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%
F3	5,0%	90,0%	5,0%	5,0%	5,0%	90,0%	5,0%	90,0%	5,0%
F4	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F5	5,0%	5,0%	90,0%	5,0%	5,0%	90,0%	90,0%	5,0%	5,0%
F6	5,0%	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%	5,0%	90,0%

F7	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F8	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%
F9	5,0%	90,0%	5,0%	90,0%	5,0%	5,0%	90,0%	5,0%	5,0%

Nuevamente, a partir de estas tablas, debe generarse la tabla completa como se muestra en la plantilla de la Tabla 4-8.

4.1.7. Caso estudio 1. Sistema de Diagnóstico. Tabla de diagnóstico

El sistema de diagnóstico generado, debe arrojar una tabla de resultados como la mostrada en la Tabla 4-10.

Tabla 4-10. Caso estudio 1. Tabla de diagnóstico

Vector de Síntomas = [S1TI1 S2LI1 S3FI2 S4TI2 S5QI1 S6FI3]	
Falla	Probabilidad
F1	
F2	
F3	
F4	
F5	
F6	
F7	
F8	
F9	

En cada fila de la tabla se consigna la probabilidad de que el vector de síntomas de entrada sea producido por cada falla en particular.

4.1.8. Caso estudio 1. Validación del diagnóstico

Para la validación del diagnóstico se utilizó el toolbox de redes Bayesianas para Matlab, que se encuentra disponible en [34].

El procedimiento consistió en construir la red Bayesiana mostrada en la Figura 4-3, asignando las probabilidades a priori de la Tabla 4-5.

Para las probabilidades condicionadas se utilizaron en primera instancia las probabilidades mostradas en la Tabla 4-6 y la Tabla 4-7. En la Tabla 4-11 se muestra el ejemplo del diagnóstico arrojado por el sistema, cuando la falla simulada es la falla F3, cuyo vector de síntomas es [N N N B A B].

Tabla 4-11. Caso estudio 1. Tabla de Diagnóstico para la falla F3

Vector de Síntomas = [S1TI1=N S2LI1=N S3FI2=N S4TI2=B S5QI1=A S6FI3=B]	
Falla	Probabilidad
F1	4,9%
F2	7,1%
F3	47,9%
F4	4,6%
F5	7,9%
F6	7,7%
F7	4,9%
F8	8,5%
F9	6,5%

En la tabla anterior se puede observar que la mayor probabilidad es arrojada para la falla F3, lo cual es coherente con la falla que se simuló.

Este procedimiento se repitió con todas las fallas de entrada, para verificar que en cada caso, el diagnóstico arrojado fuera coherente. Los resultados se resumen en la Tabla 4-12 y se muestran gráficamente en la Figura 4-4.

Tabla 4-12. Caso estudio 1. Diagnostico ante cada falla con probabilidades a priori modificadas

	F1	F2	F3	F4	F5	F6	F7	F8	F9
F1	27,6%	7,4%	7,4%	11,1%	7,7%	7,5%	8,4%	10,1%	12,9%
F2	2,6%	77,0%	1,8%	6,0%	2,8%	2,8%	1,9%	2,6%	2,3%
F3	4,9%	7,1%	47,9%	4,6%	7,9%	7,7%	4,9%	8,5%	6,5%
F4	10,9%	7,8%	7,1%	30,9%	6,9%	7,2%	7,8%	9,9%	11,5%
F5	5,5%	2,7%	1,9%	1,8%	81,2%	1,5%	1,5%	1,8%	2,1%
F6	4,2%	6,3%	5,6%	4,2%	5,8%	56,9%	4,4%	6,7%	5,9%
F7	8,9%	8,9%	8,1%	8,8%	8,1%	8,3%	25,3%	12,1%	11,5%
F8	10,5%	10,6%	9,4%	10,0%	9,3%	9,6%	10,4%	15,4%	14,9%
F9	10,5%	10,6%	9,4%	10,0%	9,3%	9,6%	10,4%	15,4%	14,9%

En la tabla, las filas corresponden a las fallas de entrada al sistema y las columnas corresponden a la probabilidad de que la falla de entrada corresponda con cada columna en particular. Por ejemplo, para la falla de entrada F3, la probabilidad arrojada por la red, de que la falla sea F1 es 4.9%, la probabilidad de que sea la falla F2 es 7.1%, la probabilidad de que sea la falla F3 es 47.9%, y así hasta llegar a la falla F9.




Figura 4-4. Caso estudio 1. Gráficos de diagnóstico de la red ante cada falla

Se puede observar que en general la red arrojó aceptables resultados. Así, obtuvo un diagnóstico acertado en 88.8% de los casos, excepto en la falla F9, en la cual la red arrojó que el diagnóstico (la mayor probabilidad) sería la falla F8. Esto se debe a que las fallas F8 y F9 tienen sintomatología idéntica y dado que tienen las mismas probabilidades a priori, la probabilidad de que la sintomatología observada corresponda con una falla o la otra es casi la misma, en la tabla se observa que la probabilidad es de 15,4% para la falla F8 y 14,9% para la falla F9. Cuando el sistema entre en operación, estas probabilidades a priori se pueden ir ajustando de acuerdo a la ocurrencia real de las fallas en el sistema productivo. La forma y el periodo para el ajuste de las probabilidades a priori deben determinarse en conjunto con los expertos. En este caso de estudio, por ejemplo, se determinó que la probabilidad a priori de la falla F8 debía incrementarse en 5%. Este incremento de la probabilidad a priori de la falla F8, produce una redistribución de todas las probabilidades a priori en las demás fallas, ya que el 5% que se incrementa la probabilidad de la falla F8, debe restarse de manera uniforme del resto de

probabilidades a priori. En la Tabla 4-13 se muestra como quedan las probabilidades a priori al ser modificadas.

Tabla 4-13. Caso estudio 1. Probabilidades a priori modificadas

Falla	Probabilidad Ocurrencia	Probabilidad No Ocurrencia
F1	10,49%	89,51%
F2	10,49%	89,51%
F3	10,49%	89,51%
F4	10,49%	89,51%
F5	10,49%	89,51%
F6	10,49%	89,51%
F7	10,49%	89,51%
F8	16,00%	84,00%
F9	10,49%	89,51%


El sistema se evaluó nuevamente para todas las fallas con las probabilidades a priori modificadas. Los resultados se resumen en la Tabla 4-14 y se muestran en la Figura 4-5

Tabla 4-14. Caso estudio 1. Diagnóstico con probabilidades a priori modificadas.


	F1	F2	F3	F4	F5	F6	F7	F8	F9
F1	26,1%	7,1%	7,1%	10,6%	7,3%	7,1%	8,0%	14,6%	12,3%
F2	2,6%	75,8%	1,8%	6,0%	2,8%	2,8%	1,9%	4,0%	2,3%
F3	4,7%	6,8%	45,5%	4,4%	7,6%	7,4%	4,8%	12,6%	6,2%
F4	10,4%	7,5%	6,7%	29,2%	6,6%	6,8%	7,5%	14,4%	10,9%
F5	5,4%	2,7%	1,9%	1,8%	80,3%	1,5%	1,5%	2,7%	2,1%
F6	4,1%	6,1%	5,4%	4,1%	5,7%	54,7%	4,2%	10,0%	5,7%
F7	8,4%	8,4%	7,7%	8,3%	7,7%	7,8%	23,7%	17,4%	10,8%
F8	9,7%	9,8%	8,7%	9,3%	8,6%	8,9%	9,6%	21,8%	13,7%
F9	9,7%	9,8%	8,7%	9,3%	8,6%	8,9%	9,6%	21,8%	13,7%

Como se puede observar al comparar la


Tabla 4-12 y la Tabla 4-14, para los eventos de falla desde F1 hasta F7, los diagnósticos siguen siendo asertivos y en cada caso las probabilidades obtenidas son similares. En el caso de la falla F8, el diagnóstico es asertivo y ahora la probabilidad asociada es mayor, esto debido a que la probabilidad a priori de la falla F8 se incrementó. Sin embargo, en el caso de la falla F9 el diagnóstico no es asertivo, ya que al tener la misma sintomatología que la falla F8, el sistema arroja un diagnóstico con probabilidad mayor en ésta última falla.




Falla de entrada F1




Falla de entrada F2




Falla de entrada F3




Falla de entrada F4




Falla de entrada F5




Falla de entrada F6



Falla de entrada F7



Falla de entrada F8



Falla de entrada F9

Figura 4-5. Caso estudio 1. Diagnóstico de la red ante cada falla, con probabilidades a priori modificadas.

Una forma de resolver el problema de diagnóstico entre las fallas F8 y F9, sería adicionar una variable síntoma cuyo comportamiento sea diferente para la falla F8 y la falla F9.

4.2. Modificación caso estudio 1. Preparación de crema desodorante.

En esta sección se propone la modificación del sistema de diagnóstico del primer caso de estudio, aplicando la agrupación de fallas con síntomas idénticos. Los primeros pasos del procedimiento siguen siendo los mismos planteados anteriormente. Estos son la delimitación del caso de estudio, la definición del sistema observador, el listado de fallas conocidas y la relación entre fallas y síntomas que se muestra en la Tabla 4-4.

4.2.1. Caso estudio 1. Definir topología considerando la agrupación de nodos

Al observar la Tabla 4-4, se puede notar que las fallas F8 y F9 tienen sintomatología idéntica. Al aplicar la agrupación de los nodos F8 y F9, la topología de la red, mostrada en la Figura 4-3 cambia y se obtiene la mostrada en la Figura 4-6.




Figura 4-6. Caso estudio 1. Topología de red con agrupación de nodos

En la figura anterior se resalta el nodo de agrupación, cuyo nombre es G1. Los nodos padre de éste nodo son las fallas F8 y F9, y todos los nodos síntomas son nodos hijos de éste nodo.

4.2.2. Caso estudio 1. Definir probabilidades considerando la agrupación de nodos

Las probabilidades a priori mostradas en la Tabla 4-5 se mantienen y deben recalcularse las probabilidades condicionadas para reflejar las nuevas conexiones de la red.

En primera instancia se obtienen las probabilidades condicionadas del nodo grupo G1. Para esto se tiene en cuenta que el nodo G1 tiene dos posibles estados, "Presente" y "No Presente", y que lo normal es que el nodo G1 esté en estado "Presente" si al menos una de las fallas que agrupa está en estado "Presente", y además también que lo normal es que el nodo G1 esté en estado "No Presente" si todas las fallas que agrupa están en estado "No Presente". Con estas consideraciones, se asigna una probabilidad de ocurrencia del 90% a los estados normales del grupo G1 y 10% a los estados no normales, como se muestra en la Tabla 4-15.

Tabla 4-15. Caso estudio 1. Probabilidades condicionadas del nodo grupo G1

	Fallas agrupadas por el nodo		Estados del nodo G1	Probabilidad
	F9	F8		
1	0	0	0	$P(G1=0 F9=0,F8=0)=90\%$
2	0	1	0	$P(G1=0 F9=1,F8=0)=10\%$
3	1	0	0	$P(G1=0 F9=0,F8=1)=10\%$
4	1	1	0	$P(G1=0 F9=1,F8=1)=10\%$
5	0	0	1	$P(G1=1 F9=0,F8=0)=10\%$
6	0	1	1	$P(G1=1 F9=1,F8=0)=90\%$
7	1	0	1	$P(G1=1 F9=0,F8=1)=90\%$
8	1	1	1	$P(G1=1 F9=1,F8=1)=90\%$

Ahora deben modificarse las probabilidades condicionadas de los síntomas para reflejar las nuevas conexiones de la red. Para ello, deben excluirse de la tabla las fallas que han sido agrupadas e incluir en la tabla el nodo de agrupación. De esta forma las probabilidades mostradas en la Tabla 4-6 y la Tabla 4-7 se modifican para obtener las probabilidades mostradas en la Tabla 4-16.

Tabla 4-16. Caso estudio 1. Tablas de probabilidad condicionada teniendo en cuenta la agrupación de fallas

	S1TI1			S2LI1			S3FI2		
	N	B	A	N	B	A	N	B	A
F1	68,0%	16,5%	15,5%	18,5%	65,0%	16,5%	73,0%	16,0%	11,0%
F2	66,0%	17,5%	16,5%	20,0%	16,5%	63,5%	16,5%	70,0%	13,5%
F3	65,5%	20,5%	14,0%	67,0%	14,5%	18,5%	61,5%	18,5%	20,0%
F4	67,5%	14,0%	18,5%	10,0%	18,5%	71,5%	71,5%	12,0%	16,5%
F5	67,5%	18,0%	14,5%	18,0%	61,5%	20,5%	13,0%	13,5%	73,5%
F6	69,5%	16,0%	14,5%	66,0%	17,5%	16,5%	71,5%	14,0%	14,5%
F7	19,5%	64,5%	16,0%	65,5%	13,5%	21,0%	67,5%	16,0%	16,5%
G1	70,0%	14,25%	15,75%	70,25%	15,0%	14,75%	63,25%	18,5%	18,25%
	S4TI2			S5QI1			S6FI3		
	N	B	A	N	B	A	N	B	A
F1	68,5%	15,5%	16,0%	65,0%	17,0%	18,0%	67,0%	20,0%	13,0%
F2	17,5%	65,0%	17,5%	17,0%	65,5%	17,5%	72,0%	15,5%	12,5%
F3	17,5%	69,5%	13,0%	15,5%	14,5%	70,0%	17,0%	64,0%	19,0%
F4	69,0%	16,5%	14,5%	72,0%	12,0%	16,0%	65,0%	22,0%	13,0%
F5	23,5%	15,5%	61,0%	16,0%	18,5%	65,5%	68,0%	13,0%	19,0%
F6	14,5%	17,5%	68,0%	12,0%	68,5%	19,5%	16,0%	19,5%	64,5%
F7	18,0%	64,5%	17,5%	64,5%	18,0%	17,5%	66,0%	16,5%	17,5%
G1	16,50%	69,25%	14,25%	71,0%	11,75%	17,25%	70,50%	14,50%	15,0%

A partir de estas probabilidades debe generarse la tabla completa, como se muestra en la Tabla 4-8, sin embargo ahora deben excluirse de la tabla las fallas F8 y F9 e incluirse el nodo de agrupación G1. Con esto, la plantilla se modifica como se muestra en la Tabla 4-17.

Tabla 4-17. Caso estudio 1. Tabla completa de probabilidades considerando la agrupación de fallas

Estados de los síntomas y probabilidades asociadas										
	G1	F7	F6	F5	F4	F3	F2	F1	S1T1	Probabilidad
1	0	0	0	0	0	0	0	0	1	$P(S1=1 G1=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=0)$
2	0	0	0	0	0	0	0	1	1	$P(S1=1 G1=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=1)$
3	0	0	0	0	0	0	1	0	1	$P(S1=1 G1=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=1,F1=0)$
4	0	0	0	0	0	0	1	1	1	$P(S1=1 G1=0,F7=0,F6=0,F5=0,F4=0,F3=0,F2=0,F1=0)$
5	0	0	0	0	0	1	0	0	1	$P(S1=1 G1=0,F7=0,F6=0,F5=0,F4=0,F3=1,F2=0,F1=0)$

Así, el número total de probabilidades condicionadas en esta tabla es $(2^{(7+1)} \times 3) \times 6 = 4608$, distribuidas en 768 filas, y el número total de probabilidades condicionadas, incluyendo las del nodo de agrupación, de acuerdo a la Ecuación 3-3 sería

$$NP = [(2^2) \times 2] + (2^{(7+1)} \times 6) \times 3 = 4616$$

Esto es 4616 probabilidades condicionadas, que en comparación con las 9216 probabilidades condicionadas que tiene el sistema original, representan una reducción de aproximadamente el 50%, generando una disminución en el costo computacional, haciendo el sistema de inferencia más rápido y obteniendo cualitativamente los mismos resultados que se obtuvieron en la etapa de validación.

4.2.3. Caso estudio 1. Tabla de diagnóstico y validación

El sistema de diagnóstico obtenido produce una tabla de diagnóstico igual a la de la Tabla 4-10. Durante el proceso de validación no se observaron diferencias considerables en cuanto a las probabilidades arrojadas en cada diagnóstico, al compararlos con los resultados mostrados en la Tabla 4-12 y la Figura 4-4, por ello no se incluyen nuevamente los resultados. En ese sentido, se puede afirmar que la agrupación de los nodos no afecta de manera significativa el diagnóstico como tal, pero si reduce el costo computacional del sistema.

4.3. Caso estudio 2. Proceso de potabilización de agua

La importancia del agua potable para una comunidad, es un tema que se remonta a los griegos, de quiénes se conoce, por referencias históricas (siglo v a.C), su preocupación por la calidad del agua, pues ya tenían conocimiento de que ésta era capaz de transmitir enfermedades, por ello recomendaban su filtración y hervido antes de su ingestión [35]. Actualmente, la Organización Mundial de la Salud (OMS) reconoce de igual manera la importancia de la calidad en el agua para el consumo humano, no sólo desde el punto de vista de la salud humana como tal, sino también como un factor que puede impactar el nivel de vida de una comunidad al tener en cuenta los impactos económicos que un problema de salubridad puede acarrear. Esto queda evidenciado en el siguiente texto tomado de [36].

El acceso al agua potable es una cuestión importante en materia de salud y desarrollo en los ámbitos nacional, regional y local. En algunas regiones, se ha comprobado que las inversiones en sistemas de abastecimiento de agua y de saneamiento pueden ser rentables desde un punto de vista económico, ya que la disminución de los efectos adversos para la salud y la consiguiente reducción de los costos de asistencia sanitaria es superior al costo de las intervenciones. Dicha afirmación es válida para diversos tipos de inversiones, desde las grandes infraestructuras de abastecimiento de agua al tratamiento del agua en los hogares. La experiencia ha demostrado asimismo que las medidas destinadas a mejorar el acceso al agua potable favorecen en particular a los pobres, tanto de zonas rurales como urbanas, y pueden ser un componente eficaz de las estrategias de mitigación de la pobreza.

La garantía de la inocuidad microbiana del abastecimiento de agua de consumo (agua potable) se basa en la aplicación, desde la cuenca de captación al consumidor, de barreras múltiples para evitar la contaminación del agua de consumo o para reducirla a niveles que no sean perjudiciales para la salud [36]. Las etapas y procesos de potabilización varían en función de las características y proveniencia del agua (fuente de captación). El objetivo es eliminar los microorganismos y partículas que se encuentran en ella, para lo cual se recurre a procesos físicos y químicos de tratamiento [37].

Para este caso de estudio se seleccionó la Planta de Tratamiento de Agua Potable (PTAP) “Puerto Mallarino”, ubicada en la ciudad de Cali, Colombia. Cali es una ciudad con 2’319.655 habitantes[38] y la PTAP Puerto Mallarino abastece el 60%

del agua potable que ésta consume¹. El trabajo se desarrolló en el marco del proyecto “DESARROLLO DE SISTEMAS PRODUCTIVOS AUTODIAGNÓSTICABLES”, financiado por COLCIENCIAS con referencia al número de contrato 2648, con el apoyo y colaboración de las Empresas Públicas Municipales, EMCALI EICE ESP de la ciudad de Cali.

En la Figura 4-7 se muestra una vista general de este sistema productivo.




Figura 4-7. Caso estudio 2. Esquema general del proceso[39]

En la se Figura 4-8 muestra el diagrama de bloques del proceso. En la figura se distinguen los siguientes elementos:

- **RIO CAUCA.** Es el río que proporciona el agua para el consumo que abastece la PTAP Puerto Mallarino.
- **ESTACIÓN MILAN.** Estación de alerta temprana ubicada aproximadamente a 5 Km aguas arriba de la bocatoma de la planta. Esta estación cuenta con sensores de turbiedad, pH, oxígeno disuelto y conductividad del agua. Al estar ubicada aguas arriba, puede proveer información temprana acerca de las condiciones del río, entre tres (3) y cuatro (4) horas antes de que las aguas lleguen a la bocatoma.

¹ Información suministrada por el señor Juan Carlos Escobar, Gerente de las Empresas Públicas Municipales, EMCALI EICE ESP de la ciudad de Cali, en el año 2014.




Figura 4-8. Caso estudio 2. Diagrama de bloques general PTAP Puerto Mallarino

- **BOCATOMA.** Es la primera etapa del proceso de tratamiento y se encarga de captar el agua proveniente del Río Cauca, a través de un conjunto de bombas y motores. En esta se hace un primer filtrado mediante rejillas, para eliminar elementos grandes en suspensión. Cuenta también con sensores de turbiedad, nivel, pH, conductividad y oxígeno disuelto.
- **DESARENADORES.** Son un conjunto de tamices, donde se remueven los objetos de cierto tamaño que lograron atravesar las rejillas de la bocatoma. En esta etapa se aplica carbón activado para remover olores y sabores. Además, Cuenta con sensores de turbiedad y caudal.
- **CADICA.** Es la caja de distribución de caudales. Permite direccionar el caudal hacia los vertederos de los reactores, donde se suministra el coagulante (cloruro férrico) y se genera una elevada turbulencia para asegurar la disolución del mismo. El objetivo del coagulante es permitir la clarificación del agua, mediante la agrupación de partículas que luego son filtradas con lodos. Cuenta con sensores de pH y nivel. En esta etapa del proceso, se toma una muestra del agua en proceso para ser analizada en el laboratorio.

- **REACTORES.** Son contenedores donde tiene lugar el proceso de floculación y clarificación. Para ello, el reactor cuenta con una turbina que genera un movimiento rotativo, con lo que se realiza la recirculación de los lodos, generando el floc (agrupamiento de partículas). Posteriormente, el agua pasa por el manto de lodos del reactor, y por medio de sedimentación se produce la clarificación. Los reactores cuentan con sensores de nivel de lodos y sensores de turbiedad.
- **FILTROS RÁPIDOS.** Se encargan de retener pequeñas partículas que logran superar los procesos anteriores.
- **CLORACIÓN.** Es el proceso final. Se aplica cloro al agua para remover agentes peligrosos. Además, se aplica cal para estabilizar el pH y se pasa a distribución.
- **DISTRIBUCIÓN.** Conjunto de elementos que permiten el bombeo del agua de consumo a la red de distribución.
- **CUARTO DE CONTROL.** Es el centro de control operativo de la planta. En este se tiene la información de los sensores ubicados en campo en cada etapa del proceso y se toman las decisiones operativas del mismo.
- **LABORATORIO.** En este se toman las decisiones respecto del control químico del agua, dosificación y control de calidad de las materias primas. Además, se realizan pruebas del proceso de tratamiento, como la prueba de jarras, que es una técnica donde se simula el proceso de clarificación del agua cruda. Entre las funciones que se realizan en el laboratorio están: determinar la dosis óptima de coagulante, considerando la calidad del agua; determinar el pH óptimo para la coagulación; evaluar el resultado de los diferentes productos químicos utilizados en la clarificación del agua cruda, tanto coagulantes, como ayudantes de coagulación y/o floculación, etc; determinar y optimizar las variables químicas del proceso de coagulación y/o floculación; tomar decisiones rápidas en la dosificación, cuando hay variaciones en la calidad del agua cruda.

4.3.1. Caso estudio 2. Delimitar el caso de estudio

Dado que el proceso de potabilización del agua es complejo y comprende varias etapas, para este proyecto se decidió tomar solo una. En ese sentido, se escogió la ESTACIÓN MILAN. Esta es la etapa primaria de la planta de tratamiento, y es la

encargada de medir las condiciones de turbiedad, pH, conductividad y Oxígeno disuelto aguas arriba del río. En esta etapa, están acondicionados un conjunto de cuatro (4) sensores que miden las variables anteriormente descritas. La información proveída por la estación MILAN es de suma importancia, dado que las decisiones respecto del tratamiento químico del agua dependen de las condiciones del río, y la estación MILAN permite tener información de éstas condiciones antes de que el agua llegue a BOCATOMA. Así, al garantizar el correcto funcionamiento de los sensores ubicados en la estación MILAN, se mejora la confiabilidad de la información y se pueden tomar decisiones más asertivas en el tratamiento químico del agua.

En la Tabla 4-18 se listaron las variables observables del proceso. Estas variables son la turbiedad, pH, conductividad y oxígeno disuelto del río. Se muestran en la tabla también los rangos normales de operación, y los estados bajos y altos de cada una.

Tabla 4-18. Caso estudio 2. Variables del sistema

Tag	Descripción	Rango Normal	Anormalidad	
			Bajo	Alto
S1T	Turbiedad del río aguas arriba	50-2000	0-50	>2000
S2pH	pH del río aguas arriba	6.5-7.5	<6.5	>7.2
S3OD	Oxígeno Disuelto en el río aguas arriba	4-7	<4	>7
S4C	Conductividad del río aguas arriba	30-100	<30	>100

4.3.2. Caso estudio 2. Definir el sistema observador

En el marco del proyecto SISTEMAS PRODUCTIVOS AUTODIAGNÓSTICABLES², se desarrolló un sistema supervisor que pudiera funcionar como observador del sistema productivo. Este sistema observador fue desarrollado utilizando herramientas de la inteligencia artificial, específicamente lógica difusa en un sistema experto basado en reglas heurísticas presentadas en un formato condicionado del tipo IF-THEN. Para esto, en el proyecto, se propuso una etapa de detección y localización de anomalías en el proceso productivo, gobernada por la información de condiciones normales para las variables de proceso, en la que se encuentran correlaciones y rangos de aceptabilidad. Esta información es producto del conocimiento de expertos, antecedentes históricos y

² Proyecto de investigación financiado por COLCIENCIAS, con código 4628.

nociones teóricas. La arquitectura propuesta para el bloque de detección y localización se muestra en la Figura 4-9.




Figura 4-9. Caso estudio 2. Bloque Observador

Este bloque observador, debe arrojar un vector de síntomas cada hora, y este vector de síntomas deberá consignarse en una bitácora como la mostrada en la Tabla 3-2, a partir de la cual se alimenta el bloque de inferencia (diagnóstico).

Tabla 4-19. Caso estudio 2. Tabla con vectores de síntomas

Tiempo	Estados (Vector de síntomas)			
	S1T	S2pH	S3OD	S4C
0	Valor de S1T en t = 0	Valor de S2pH en t=0	Valor de S3OD en t=0	Valor de S4C en t=0

Para la detección y localización de las anomalías, se leen del proceso los valores correspondientes a cada variable y se comparan con los valores máximos y mínimos permisibles para la operación normal del proceso. Para la comparación se utiliza un cuadro de correlaciones reales del comportamiento de todas las variables implicadas. Cuando la información no coincide con la plasmada en el cuadro de correlaciones, se puede determinar que un sensor está funcionando por fuera de lo que se considera normal.

Para información más detallada acerca del sistema supervisor construido, remitirse al proyecto SISTEMA DE ALERTA TEMPRANA DE FALLAS, MEDIANTE

UN MOTOR DE INFERENCIA EURÍSTICO, APLICADO EN LA PLANTA DE TRATAMIENTO DE AGUA DE PUERTO MALLARINO³.

4.3.3. Caso estudio 2. Listar las fallas conocidas

Para obtener el listado de fallas conocidas se consultó a los operarios del sistema productivo, quiénes indicaron el listado de fallas mostrado en la Tabla 4-20.

Tabla 4-20.Caso estudio 2. Listado de fallas conocidas

Falla		Síntomas que afecta			
Tag	Descripción	S1T	S2pH	S3OD	S4C
F1	Sensor de turbiedad fuera del rio.	Si	No	No	No
F2	Sensor de turbiedad obstruido	Si	No	No	No
F3	Sensor de turbiedad descalibrado (Lectura Baja)	Si	No	No	No
F4	Sensor de turbiedad descalibrado (Lectura alta)	Si	No	No	No
F5	Sensor de pH fuera del rio	No	Si	No	No
F6	Sensor de pH Obstruido	No	Si	No	No
F7	Sensor de pH descalibrado (Lectura baja)	No	Si	No	No
F8	Sensor de pH descalibrado (Lectura alta)	No	Si	No	No
F9	Sensor de oxígeno disuelto fuera del rio	No	No	Si	No
F10	Sensor de oxígeno disuelto Obstruido	No	No	Si	No
F11	Sensor de oxígeno disuelto descalibrado (Lectura baja)	No	No	Si	No
F12	Sensor de oxígeno disuelto descalibrado (Lectura alta)	No	No	Si	No
F13	Sensor de conductividad fuera del rio.	No	No	No	Si
F14	Sensor de conductividad obstruido	No	No	No	Si
F15	Sensor de conductividad descalibrado (Lectura Baja)	No	No	No	Si
F16	Sensor de conductividad descalibrado (Lectura alta)	No	No	No	Si

En la tabla se describe cada una de las fallas y se muestra los síntomas que se afectan en presencia de cada falla. Por ejemplo, la presencia de la falla F1 afecta el síntoma S1T1, mientras que la presencia de la falla F5 afecta el síntoma S2pH. Se puede observar que en la tabla sólo interesa especificar que síntomas se afectan y no de qué manera se afectan.

4.3.4. Caso estudio 2. Relacionar fallas y síntomas

En esta etapa debe definirse cómo afecta la presencia de cada falla a cada uno de los síntomas, teniendo en cuenta que cada síntoma puede asumir uno de tres valores, “Normal (N)”, “Bajo (B)” y “Alto (A)”. Para ello, se consultó con los expertos cuáles eran los estados normales de los síntomas en presencia de las fallas. Los resultados se resumen en la Tabla 4-21. En esta tabla se puede observar que hay varias fallas que tienen sintomatología idéntica. En este caso se aplicará directamente el procedimiento de reducción de fallas. Si este proceso de reducción no se aplicara, o si las dieciséis (16) fallas tuvieran todas sintomatología diferente, de acuerdo a la Ecuación 3-1, se tendrían

³ Proyecto financiado por la Universidad del Valle, con código 2760

$$NP = (2^{NF} \times 3) \times NS = (2^{16} \times 3) \times 4 = 786.432$$

Esto es 786.432 probabilidades, distribuidas en una tabla de 65.536 filas. Debe recordarse que, dada la consideración de que sólo una falla puede estar presente en cualquier momento, el número real de probabilidades a obtener está dado por la Ecuación 3-2

$$NP = [3 \times (NF + 1)] \times NS = [3 \times (16 + 1)] \times 4 = 204$$

Las otras 786.228 probabilidades que hacen falta se obtendrían a partir de las 204 ya obtenidas. Para más información de este procedimiento, consultar la sección 3.1.6

Tabla 4-21. Caso estudio 2. Estados normales de los síntomas ante las fallas

Falla	S1T	S2pH	S3OD	S4C
F1	B	N	N	N
F2	B	N	N	N
F3	B	N	N	N
F4	A	N	N	N
F5	N	B	N	N
F6	N	A	N	N
F7	N	B	N	N
F8	N	A	N	N
F9	N	N	A	N
F10	N	N	B	N
F11	N	N	B	N
F12	N	N	A	N
F13	N	N	N	B
F14	N	N	N	B
F15	N	N	N	B
F16	N	N	N	A

Como se mencionó anteriormente, para este caso se aplicará la reducción de fallas. En la siguiente sección se especifica ese procedimiento.

4.3.5. Identificar fallas con síntomas idénticos.

Para este paso, deben verificarse la forma en que cada falla afecta los síntomas. El objetivo es determinar que fallas producen el mismo tipo de afectación en los síntomas, sin tener en cuenta que tanto afectan cada síntoma. En la Tabla 4-21 se han agrupado por colores las fallas que tienen sintomatología idéntica observando sólo los valores discretos de los estados que puede alcanzar cada síntoma.

4.3.6. Caso estudio 2. Agrupar fallas con síntomas idénticos

A partir de la información consignada en la Tabla 4-21, se identifican los nodos de agrupación y se agrupan y se llevan a una plantilla como la mostrada en la Tabla 2-1. En la

Tabla 4-22 se muestran los nodos de agrupación obtenidos para este caso.

Tabla 4-22. Caso estudio 2. Nodos de agrupación identificados

Nodo Grupo	Fallas que agrupa	Estados asociados de las variables síntoma [S1T S2pH S3OD S4C]
G1	F1, F2, F3	[B N N N]
G2	F5, F7	[N B N N]
G3	F6, F8	[N A N N]
G4	F9, F12	[N N A N]
G5	F10, F11	[N N B N]
G6	F13, F14, F15	[N N N B]

En la tabla anterior se observa que se han identificado seis (6) nodos de agrupación.

4.3.7. Caso estudio 2. Definir la topología

Para la construcción de esta red se tienen dieciséis (16) nodos de falla, cuatro (4) nodos síntoma y cinco (5) nodos de agrupación. A partir de esta información, se construye la red como se muestra en la Figura 4-10.




Figura 4-10. Caso de estudio 2. Red de diagnóstico

En la figura anterior se han resaltado los nodos de agrupación. Se puede observar, al extremo derecho, que los nodos F4 y F16 son los únicos que no están incluidos en ninguno de los grupos definidos.

4.3.8. Caso estudio 2. Definir probabilidades

Definida la topología, se pasa a la construcción paramétrica, en la que se definen las probabilidades a priori de los nodos padres y las probabilidades condicionadas de los nodos hijos.

Para las probabilidades a priori, dado que no se cuenta con información precisa en cuanto a la probabilidad de ocurrencia de las fallas identificadas, se distribuyó de manera uniforme esta probabilidad entre todas las fallas. De esta manera, considerando que se tienen dieciséis (16) fallas, las probabilidades a priori de ocurrencia de los nodos falla se establece en $1/16$, es decir, 6.3%, y la probabilidad de no ocurrencia se establece en $1-1/16$, es decir, 93.8%. En la Tabla 4-23 se muestran estas probabilidades.

Tabla 4-23. Caso estudio 2. Probabilidades a priori

Falla	Probabilidad de ocurrencia (%)	Probabilidad de no ocurrencia (%)
F1	$1/16 \rightarrow 6.3\%$	93.8%
F2	$1/16 \rightarrow 6.3\%$	93.8%
F3	$1/16 \rightarrow 6.3\%$	93.8%
F4	$1/16 \rightarrow 6.3\%$	93.8%
F5	$1/16 \rightarrow 6.3\%$	93.8%
F6	$1/16 \rightarrow 6.3\%$	93.8%
F7	$1/16 \rightarrow 6.3\%$	93.8%
F8	$1/16 \rightarrow 6.3\%$	93.8%
F9	$1/16 \rightarrow 6.3\%$	93.8%
F10	$1/16 \rightarrow 6.3\%$	93.8%
F11	$1/16 \rightarrow 6.3\%$	93.8%
F12	$1/16 \rightarrow 6.3\%$	93.8%
F13	$1/16 \rightarrow 6.3\%$	93.8%
F14	$1/16 \rightarrow 6.3\%$	93.8%
F15	$1/16 \rightarrow 6.3\%$	93.8%
F16	$1/16 \rightarrow 6.3\%$	93.8%

Para obtener las probabilidades condicionadas de los nodos de agrupación, se siguió el procedimiento planteado en la sección 3.2.8. En la Tabla 4-24 y la Tabla 4-25 se muestran las probabilidades obtenidas para los nodos G1 y G2 respectivamente.

Tabla 4-24.Caso estudio 2. Probabilidades condicionadas del nodo grupo G1

	Fallas agrupadas por el nodo G1			Estados del nodo G1	Probabilidad
	F3	F2	F1		
1	0	0	0	0	$P(G1=0 F1=0,F2=0,F3=0)=90\%$
2	0	0	1	0	$P(G1=0 F1=1,F2=0,F3=0)=10\%$
3	0	1	0	0	$P(G1=0 F1=0,F2=1,F3=0)=10\%$
4	0	1	1	0	$P(G1=0 F1=1,F2=1,F3=0)=10\%$
5	1	0	0	0	$P(G1=0 F1=0,F2=0,F3=1)=10\%$
6	1	0	1	0	$P(G1=0 F1=1,F2=0,F3=1)=10\%$
7	1	1	0	0	$P(G1=0 F1=0,F2=1,F3=1)=10\%$
8	1	1	1	0	$P(G1=0 F1=1,F2=1,F3=1)=10\%$
9	0	0	0	1	$P(G1=1 F1=0,F2=0,F3=0)=10\%$
10	0	0	1	1	$P(G1=1 F1=1,F2=0,F3=0)=90\%$
11	0	1	0	1	$P(G1=1 F1=0,F2=1,F3=0)=90\%$
12	0	1	1	1	$P(G1=1 F1=1,F2=1,F3=0)=90\%$
13	1	0	0	1	$P(G1=1 F1=0,F2=0,F3=1)=90\%$
14	1	0	1	1	$P(G1=1 F1=1,F2=0,F3=1)=90\%$
15	1	1	0	1	$P(G1=1 F1=0,F2=1,F3=1)=90\%$
16	1	1	1	1	$P(G1=1 F1=1,F2=1,F3=1)=90\%$

Tabla 4-25.Caso estudio 2. Probabilidades condicionadas del nodo grupo G2

	Fallas agrupadas por el nodo G2		Estados del nodo G2	Probabilidad
	F7	F5		
1	0	0	0	$P(G2=0 F5=0,F7=0)=90\%$
2	0	1	0	$P(G2=0 F5=1,F7=0)=10\%$
3	1	0	0	$P(G2=0 F5=0,F7=1)=10\%$
4	1	1	0	$P(G2=0 F5=1,F7=1)=10\%$
5	0	0	1	$P(G2=1 F5=0,F7=0)=10\%$
6	0	1	1	$P(G2=1 F5=1,F7=0)=90\%$
7	1	0	1	$P(G2=1 F5=0,F7=1)=90\%$
8	1	1	1	$P(G2=1 F5=1,F7=1)=90\%$

Para obtener las tablas de probabilidad condicionada, se partió de la información acerca del estado normal de los síntomas en presencia de cada falla, mostrada en la Tabla 4-21. Se utilizó esta aproximación porque no existen registros históricos que describan el comportamiento de las variables en presencia de cada falla y no se puede interrumpir el proceso productivo para inducir las fallas directamente en el sistema. A partir de esta tabla de estados normales, se definen las probabilidades condicionadas, asociando una probabilidad del 90% al estado que normalmente se presenta ante la falla, y distribuyendo de manera uniforme el 10% restante entre los otros dos estados. En la Tabla 4-26 se muestran las probabilidades asignadas.

Tabla 4-26. Caso estudio 2. Probabilidades condicionadas a partir de estados normales en falla

	S1T			S2Ph			S3OD			S4C		
	N	B	A	N	B	A	N	B	A	N	B	A
F1	5%	90%	5%	90%	5%	5%	90%	5%	5%	90%	5%	5%
F2	5%	90%	5%	90%	5%	5%	90%	5%	5%	90%	5%	5%
F3	5%	90%	5%	90%	5%	5%	90%	5%	5%	90%	5%	5%
F4	5%	5%	90%	90%	5%	5%	90%	5%	5%	90%	5%	5%
F5	90%	5%	5%	5%	90%	5%	90%	5%	5%	90%	5%	5%
F6	90%	5%	5%	5%	5%	90%	90%	5%	5%	90%	5%	5%
F7	90%	5%	5%	5%	90%	5%	90%	5%	5%	90%	5%	5%
F8	90%	5%	5%	5%	5%	90%	90%	5%	5%	90%	5%	5%
F9	90%	5%	5%	90%	5%	5%	5%	5%	90%	90%	5%	5%
F10	90%	5%	5%	90%	5%	5%	5%	90%	5%	90%	5%	5%
F11	90%	5%	5%	90%	5%	5%	5%	90%	5%	90%	5%	5%
F12	90%	5%	5%	90%	5%	5%	5%	5%	90%	90%	5%	5%
F13	90%	5%	5%	90%	5%	5%	90%	5%	5%	5%	90%	5%
F14	90%	5%	5%	90%	5%	5%	90%	5%	5%	5%	90%	5%
F15	90%	5%	5%	90%	5%	5%	90%	5%	5%	5%	90%	5%
F16	90%	5%	5%	90%	5%	5%	90%	5%	5%	5%	5%	90%

En la tabla anterior se resaltan las fallas para las que se afecta cada síntoma. A partir de esta tabla se define la tabla de probabilidades completa, de acuerdo a la plantilla mostrada en la Tabla 3-25. Al obtener la tabla completa, se obtiene una tabla con $(2^{(2+6)} \times 3) \times 4 = 3.072$ probabilidades, distribuidas en 768 filas. Por cuestiones de espacio no se muestra la tabla completa y sólo se muestra, en la Tabla 4-27, el encabezado con algunas de las probabilidades definidas.

Tabla 4-27. Caso estudio 2. Tabla de probabilidades condicionadas de los síntomas

Estados de las fallas y grupos								Estados de los síntomas y probabilidades							
F16	F4	G6	G5	G4	G3	G2	G1	S1T	P	S2pH	P	s3OD	P	s4C	P
0	0	0	0	0	0	0	0	1	90%	1	90%	1	90%	1	90%
0	0	0	0	0	0	0	1	1	5%	1	90%	1	90%	1	90%
0	0	0	0	0	0	1	0	1	90%	1	5%	1	90%	1	90%
0	0	0	0	0	0	1	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	0	1	0	0	1	90%	1	5%	1	90%	1	90%
0	0	0	0	0	1	0	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	0	1	1	0	1	90%	1	90%	1	90%	1	90%
0	0	0	0	0	1	1	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	0	0	0	1	90%	1	90%	1	5%	1	90%

0	0	0	0	1	0	0	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	0	1	0	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	0	1	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	1	0	0	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	1	0	1	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	1	1	0	1	90%	1	90%	1	90%	1	90%
0	0	0	0	1	1	1	1	1	90%	1	90%	1	90%	1	90%
0	0	0	1	0	0	0	0	1	90%	1	90%	1	5%	1	90%

De esta manera, el número total de probabilidades condicionadas que debe computar el sistema de diagnóstico, incluyendo las probabilidades condicionadas de los nodos de agrupación y de los nodos síntomas, según la Ecuación 3-3, sería:

$$NP = [(2^3) \times 2] + [(2^2) \times 2] + [(2^2) \times 2] + [(2^2) \times 2] + [(2^2) \times 2] + [(2^3) \times 2] + (2^{(2+6)} \times 3) \times 4 = 3.136$$

Esto es, 3.136 probabilidades condicionadas, frente a 786.432 que deberían computarse si no se hace la reducción de fallas con síntomas idénticos.

4.3.9. Caso estudio 2. Sistema de Diagnóstico. Tabla de diagnóstico.

El sistema de diagnóstico generado, debe arrojar una tabla de resultados como la mostrada en la Tabla 4-10. En la Tabla 4-28 se observa la tabla de diagnóstico para uno de los vectores de síntomas.

Tabla 4-28. Caso estudio 2. Tabla de diagnóstico

Vector de Síntomas = [S1T S2pH S3OD S4C]	
Falla	Probabilidad
F1	
F2	
F3	
F4	
F5	
F6	
F7	
F8	
F9	
F10	

F11	
F12	
F13	
F14	
F15	
F16	

En cada fila de la tabla se consigna la probabilidad de que el vector de síntomas de entrada sea producido por cada falla en particular.

4.3.10. Caso estudio 2. Validación del diagnóstico

Para la validación del diagnóstico se utilizó el toolbox de redes Bayesianas para Matlab, que se encuentra disponible en [34].

El procedimiento consistió en validar por separado los bloques OBSERVADOR y DIAGNÓSTICO. Para detalles acerca de la validación del bloque observador, remitirse al proyecto SISTEMA DE ALERTA TEMPRANA DE FALLAS, MEDIANTE UN MOTOR DE INFERENCIA EURÍSTICO, APLICADO EN LA PLANTA DE TRATAMIENTO DE AGUA DE PUERTO MALLARINO⁴. Para el bloque de DIAGNÓSTICO, lo que se hizo fue construir la red Bayesiana mostrada en la Figura 4-10, asignando las probabilidades a priori de la Tabla 4-23. Las tablas de probabilidad condicionada para los nodos de agrupación y los nodos síntomas no se muestran en este documento porque son demasiado extensas.

Una vez construida la red Bayesiana, se pasó a simular cada uno de los vectores de síntoma verificando que el diagnóstico fuera asertivo en cada caso. En la Tabla 4-29 se muestra un ejemplo de diagnóstico cuando la falla de entrada es F2 y en la Tabla 4-30 se muestra un ejemplo de diagnóstico cuando la falla de entrada es F4.

En la Tabla 4-29 se puede observar que cuando la falla de entrada es la falla F2, el sistema arroja las mayores probabilidades para F1, F2 y F3, más aún, se puede observar que las tres probabilidades son iguales. Esto es debido a que las tres fallas tienen la misma sintomatología y además tienen las mismas probabilidades a priori. Si las fallas tuvieran probabilidades a priori diferentes, se observaría un desequilibrio entre las tres probabilidades, pero igual seguirían siendo las mayores de la tabla.

⁴ Proyecto financiado por la Universidad del Valle, con código 2760

Tabla 4-29.Caso estudio 2. Tabla de diagnóstico para la falla F2

Vector de Síntomas = [S1T=B S2pH=N S3OD=N S4C=N]	
Falla	Probabilidad
F1	17,47%
F2	17,47%
F3	17,47%
F4	3,35%
F5	2,99%
F6	2,99%
F7	2,99%
F8	2,99%
F9	2,99%
F10	2,99%
F11	2,99%
F12	2,99%
F13	2,97%
F14	2,97%
F15	2,97%
F16	2,64%

Tabla 4-30.Caso estudio 2. Tabla de diagnóstico para la falla F4

Vector de Síntomas = [S1T=A S2pH=N S3OD=N S4C=N]	
Falla	Probabilidad
F1	6,43%
F2	6,43%
F3	6,43%
F4	31,15%
F5	5,03%
F6	5,03%
F7	5,03%
F8	5,03%
F9	5,03%
F10	5,03%
F11	5,03%
F12	5,03%
F13	4,96%
F14	4,96%
F15	4,96%
F16	5,09%

En la Tabla 4-30 se observa que la mayor probabilidad es arrojada para la falla F4 y no hay ninguna otra falla con probabilidad igual o cercana. Esto es debido a que la falla F4 no se agrupó en ningún nodo y tiene una sintomatología que es completamente distinta a las de las demás fallas.


Este procedimiento se repitió con todas las fallas de entrada, para verificar que en cada caso, el diagnóstico arrojado fuera coherente. Los resultados se resumen en la Tabla 4-31 y se muestran gráficamente en la Figura 4-11.

En la Tabla 4-31, las filas corresponden a las fallas de entrada al sistema y las columnas corresponden a la probabilidad de que la falla de entrada corresponda con cada columna en particular. Por ejemplo, para la falla de entrada F3, la probabilidad arrojada por la red de que la falla sea F1 es 17,47%, la probabilidad de que sea la falla F2 es 7,47%, la probabilidad de que sea la falla F3 es 17,47%, la probabilidad de que sea la falla F4 es 3.35%, y así sucesivamente hasta llegar a la falla F16.


Se puede observar que los diagnósticos arrojados por la red son asertivos y coherentes. Sin embargo, cuando se presentan fallas que comparten la misma sintomatología que otras fallas, es difícil para el sistema predecir exactamente cuál es la falla presente, es por ello que arroja probabilidades altas para todas aquellas fallas que podrían estar causando la sintomatología presente.

Tabla 4-31. Caso estudio 2.Diagnóstico de la red ante cada falla


	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	F16
F1	17,47 %	17,47 %	17,47%	3,35%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,97%	2,97%	2,97%	2,64%
F2	17,47 %	17,47 %	17,47%	3,35%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,97%	2,97%	2,97%	2,64%
F3	17,47 %	17,47 %	17,47%	3,35%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,97%	2,97%	2,97%	2,64%
F4	6,43%	6,43%	6,43%	31,15 %	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	4,96%	4,96%	4,96%	5,09%
F5	3,28%	3,28%	3,28%	3,02%	19,13 %	4,14%	19,13 %	4,14%	3,31%	3,31%	3,31%	3,28%	3,28%	3,28%	3,02%	3,02%
F6	3,28%	3,28%	3,28%	3,02%	4,14%	19,13 %	4,14%	19,13 %	3,31%	3,31%	3,31%	3,28%	3,28%	3,28%	3,02%	3,02%
F7	3,28%	3,28%	3,28%	3,02%	19,13 %	4,14%	19,13 %	4,14%	3,31%	3,31%	3,31%	3,28%	3,28%	3,28%	3,02%	3,02%
F8	3,28%	3,28%	3,28%	3,02%	4,14%	19,13 %	4,14%	19,13 %	3,31%	3,31%	3,31%	3,28%	3,28%	3,28%	3,02%	3,02%
F9	3,28%	3,28%	3,28%	3,02%	3,31%	3,31%	3,31%	3,31%	19,13 %	4,14%	4,14%	19,13 %	3,28	3,28	3,28	3,02%
F10	3,28%	3,28%	3,29%	3,02%	3,31%	3,31%	3,31%	3,31%	4,14%	19,13 %	19,13 %	4,14%	3,28%	3,28%	3,28%	3,02%
F11	3,28%	3,28%	3,29%	3,02%	3,31%	3,31%	3,31%	3,31%	4,14%	19,13 %	19,13 %	4,14%	3,28%	3,28%	3,28%	3,02%
F12	3,28%	3,28%	3,28%	3,02%	3,31%	3,31%	3,31%	3,31%	19,13 %	4,14%	4,14%	19,13 %	3,28	3,28	3,28	3,02%
F13	2,97%	2,97%	2,97%	2,64%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	17,47 %	17,47 %	17,47 %	3,35%
F14	2,97%	2,97%	2,97%	2,64%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	17,47 %	17,47 %	17,47 %	3,35%
F15	2,97%	2,97%	2,975%	2,64%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	2,99%	17,47 %	17,47 %	17,47 %	3,35%
F16	4,96%	4,96%	4,96%	5,09%	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	5,03%	6,43%	6,43%	6,43%	31,15 %




Falla de entrada F1, F2, F3




Falla de entrada F4




Falla de entrada F5, F7




Falla de entrada F6, F8




Falla de entrada F9, F12



Falla de entrada F10, F11



Falla de entrada F13, F14, F15



Falla de entrada F16

Figura 4-11. Caso estudio 2. Gráficos de diagnóstico de la red ante cada falla

5. CONCLUSIONES

En este capítulo se presentan los principales resultados obtenidos con el procedimiento planteado en el capítulo 3. Se presentan algunas de las ventajas y desventajas de los sistemas de diagnóstico obtenidos a partir de la aplicación de este procedimiento y se plantean algunos trabajos futuros que se podrían seguir en investigaciones posteriores.

5.1. Resultados principales

Mediante este trabajo de investigación, se obtuvo un procedimiento genérico que permite el diseño de sistemas de diagnóstico de fallas, enfocado a sistemas productivos determinísticos, donde se pueden establecer relaciones de causa-efecto entre las diferentes variables del mismo. El procedimiento de diseño considera la separación de la etapa de detección de las fallas de la etapa de diagnóstico de las mismas. Para la etapa de detección se deja abierta la posibilidad de utilizar distintas herramientas de modelado que permitan predecir el comportamiento normal del sistema productivo bajo supervisión, tales como sistemas expertos, redes neuronales, reglas condicionales o lógica difusa. Para la etapa de diagnóstico se utiliza como herramienta el concepto de redes Bayesianas, que permite establecer la causa posible de las fallas que se presentan.

Uno de los principales objetivos durante el trabajo era mantener la mayor simplicidad posible en el diseño del sistema de diagnóstico, de manera que pudiera ser rápidamente estructurado y puesto en marcha, permitiendo al mismo tiempo la facilidad de afinación una vez estuviera construido. Esto se logró al separar el mecanismo de detección de las fallas y al utilizar la red Bayesiana tipo Naive como estructura base para el bloque de diagnóstico. En ese sentido, se observó que incluso un operario con cierta experiencia en el proceso podría servir como mecanismo de detección de las fallas, evitando así la necesidad de construir elaborados modelos del sistema productivo para hacer pruebas iniciales del sistema de diagnóstico. Por otro lado, para el bloque de diagnóstico, al usar como base una red Bayesiana tipo Naive se evita la necesidad de la intervención de un experto que defina la jerarquía de los nodos, ya que en esta red, al tener solo dos capas en las que todos los nodos padre están conectados con todos los nodos hijos, basta con definir fallas y síntomas, y conectar todas las fallas con todos los síntomas. La parametrización de la red se simplificó también, en primer lugar

restringiendo el diagnóstico a que solo haya una sola falla presente en cualquier momento, y en segundo lugar, definiendo formas simples para determinar las probabilidades. En el caso de las probabilidades a priori de las fallas se mostró que, aún si no hay expertos que las definan o registros históricos a partir de los cuáles calcularlas, es posible hacer, inicialmente, una distribución uniforme de la probabilidad, que posteriormente puede ser ajustada. En el caso de las probabilidades condicionadas es necesario tener al menos una aproximación en lo que sería el comportamiento normal de las variables ante los eventos de falla, lo que permitiría obtener estas probabilidades condicionadas aún si no hay registros históricos a partir de los cuáles calcularlas. Esta simplicidad en el cálculo de las probabilidades, aunada a la restricción de una sola falla presente, facilita en gran medida toda la parametrización de la red.

Sin embargo, la simplicidad en la estructuración del sistema de diagnóstico, trae consigo ciertas desventajas. En primer lugar, al tener una red donde todos los nodos se conectan con todos, una de las principales propiedades de las redes Bayesianas se pierde, y es que este tipo de redes muestran visualmente la relación causal entre fallas y síntomas, pero al conectar todas las fallas con todos los síntomas, esta relación causal ya no es visualmente obvia y queda oculta en los pesos de las conexiones definidos a través de las probabilidades condicionadas. Por otro lado, al tener un gran número de conexiones, su costo computacional puede llegar a ser alto, en comparación con lo que sería si sólo se definieran las conexiones realmente relevantes. En ese sentido, con el sistema propuesto, el número de probabilidades a computar crece exponencialmente con el número de nodos de fallas y síntomas, mientras que en un sistema con una estructura más específica, el número de probabilidades crecería en función de las conexiones que se hagan entre los nodos. Otra desventaja del sistema propuesto es que no puede diagnosticar con exactitud la ocurrencia de una falla, cuando ésta falla tiene sintomatología idéntica a otras fallas. El sistema de diagnóstico propuesto funciona prácticamente como un sistema de reconocimiento de patrones, y cuando dos o más fallas comparten el mismo patrón en los síntomas, el diagnóstico arrojado en un momento dado estará inclinado hacia la falla cuya ocurrencia es más frecuente, pero no necesariamente a la que esté en ese momento presente.

El procedimiento propuesto para el diseño del sistema de diagnóstico fue puesto a prueba en dos sistemas de producción de diferentes características. En el primer sistema productivo se utilizó un operario como bloque observador para detectar las fallas y la red Bayesiana se parametrizó a partir de simulaciones del comportamiento del sistema productivo ante las fallas, dada la ausencia de registros históricos y la no disponibilidad de los expertos para definir las diferentes

probabilidades. En el segundo sistema productivo se utilizó un modelo desarrollado con lógica difusa como bloque de detección y la red Bayesiana se parametrizó a partir de la noción de los expertos en cuanto al comportamiento esperado del sistema productivo ante las fallas. En ambos casos se obtuvieron resultados satisfactorios en la identificación de las fallas ante los diferentes patrones de síntomas. En los casos donde se presentaron fallas con patrones de síntomas idénticos, el sistema fue capaz de identificar el conjunto de fallas que podrían estar asociadas a la sintomatología dada.

5.2. Trabajos futuros

A partir de los resultados satisfactorios en los sistemas de diagnóstico diseñados para los dos casos de estudio abordados en este trabajo, se podría evaluar su implementación en los sistemas productivos reales. Este trabajo de implementación podría plantearse de la siguiente manera:

- Un sistema de diagnóstico fuera de línea, en el que el bloque observador sea un operario, el cual definiría manualmente los vectores de síntomas para que el bloque de diagnóstico arroje sus resultados. Estos resultados deberían validarse con el estado real del sistema productivo.
- Comprobado el sistema de diagnóstico fuera de línea, se podría diseñar el bloque observador, con la herramienta de modelado más adecuada según el proceso. Este sistema observador debería tomar los estados de las variables a partir de las señales del sistema de instrumentación del proceso y alimentar el bloque de diagnóstico con el vector de síntomas adecuado. Dado que el bloque de diagnóstico ya estaría validado, sólo debería validarse el comportamiento del bloque observador.

La implementación en un sistema productivo real, abriría el camino para definir el procedimiento de afinación del sistema de diagnóstico. El procedimiento de afinación consiste en ajustar las probabilidades a priori y condicionadas para reflejar el comportamiento real del sistema productivo. En ese sentido podría proponerse un mecanismo de ajuste de estas probabilidades que las modifique de acuerdo a lo asertivo que sean los diagnósticos arrojados. Más aún, se podría evaluar la eliminación de las relaciones causa y efecto que sean despreciables, con el fin de afinar los arcos de la estructura de la red, dejando aquellos que sean significativos para el sistema productivo.

Además, sería interesante evaluar el desempeño del sistema de diagnóstico en dos escenarios:

- Cuando falta alguna de las variables del sistema productivo, esto es, cuando no se puede determinar el valor de alguno de los síntomas. Este sería un

escenario en que se pierde comunicación temporalmente con alguno de los sistemas de medición o cuando un sensor queda por fuera durante un tiempo prolongado por daño y hay que remplazarlo, o definitivamente se desecha el sensor y no hay intención de remplazarlo. ¿Será necesario rediseñar el sistema de diagnóstico o puede seguir funcionando con el diseño inicial?

- Cuando se presenta una combinación de fallas, es decir, cuando se presentan dos o más fallas de forma simultánea. Parece obvio que la suma de dos fallas no necesariamente implica la suma de sus patrones de síntomas, sin embargo ésta hipótesis requiere ser comprobada y evaluar si el diagnóstico arrojado por el sistema de diagnóstico en estos casos, al menos esboza de alguna manera, la o las fallas que estén causando el nuevo patrón de síntomas.

6. Bibliografía

- [1] M. Hoffmann, T. Meisen, D. Schilberg, and S. Jeschke, "Multi-dimensional production planning using a vertical data integration approach: A contribution to modular factory design," *2013 10th Int. Conf. Expo Emerg. Technol. a Smarter World*, pp. 1–6, Oct. 2013.
- [2] R. MORALES, "MODELAGEM E ANÁLISE DE SISTEMAS FLEXÍVEIS DE MANUFATURA TOLERANTES À FALHAS BASEADO EM REDE BAYESIANA E REDE DE PETRI," 2009.
- [3] C. Rameback, "Process Automation Systems - History and Future," pp. 3–4.
- [4] J. H. Taylor and a. F. Sayda, "An Intelligent Architecture for Integrated Control and Asset Management for Industrial Processes," *Proc. 2005 IEEE Int. Symp. on, Mediterrean Conf. Control Autom. Intell. Control. 2005.*, pp. 1397–1404, 2005.
- [5] V. Venkatasubramanian, R. Rengaswamy, and K. Yin, "A review of process fault detection and diagnosis Part I : Quantitative model-based methods," vol. 27, pp. 293–311, 2003.
- [6] R. A. G. Morales, J. I. G. Melo, and P. E. Miyagi, "Diagnosis and Treatment of Faults in Productive Systems based on Bayesian Networks and Petri Net," in *2007 IEEE International Conference on Automation Science and Engineering*, 2007, pp. 357–362.
- [7] V. Venkatasubramanian, "ABNORMAL EVENTS MANAGEMENT IN COMPLEX PROCESS PLANTS : CHALLENGES AND OPPORTUNITIES IN," in *Foundations of Computer-Aided Process Operations*, 2003, pp. 117–132.
- [8] S. Wang and T. Holden, "An intelligent simulation architecture for hazard and operability analysis of large-scale process plant," *Model Build. Aids ...*, pp. 8/1–8/5, 1991.
- [9] M.-H. Mazouni and J.-F. Aubry, "A PHA based on a systemic and generic ontology," *2007 IEEE Int. Conf. Serv. Oper. Logist. Informatics*, pp. 1–6, Aug. 2007.
- [10] S. Tateno, H. Matsuyama, and Y. Tsuge, "Fault Diagnosis Method Using a Signed Digraph," pp. 3271–3276, 2006.
- [11] V. Venkatasubramanian, R. Rengaswamy, and S. N. Kavuri, "A review of process fault detection and diagnosis Part II : Qualitative models and search strategies," vol. 27, pp. 313–326, 2003.
- [12] V. Venkatasubramanian, R. Rengaswamy, and S. N. Kavuri, "A review of process fault detection and diagnosis Part III : Process history based methods," vol. 27, 2003.

- [13] D. Gorinevsky, "Bayesian Fault Isolation in Multivariate Statistical Process Monitoring," no. 7, pp. 1963–1968, 2011.
- [14] K. R. Joshi, M. a. Hiltunen, W. H. Sanders, and R. D. Schlichting, "Probabilistic Model-Driven Recovery in Distributed Systems," *IEEE Trans. Dependable Secur. Comput.*, vol. 8, no. 6, pp. 913–928, Nov. 2011.
- [15] B. Hu and S. Qin, "An effective fault detection approach for electrical equipment of propulsion system in a type of vessel based on subjective Bayesian principle," *Proc. 2011 9th Int. Conf. Reliab. Maintainab. Saf.*, pp. 970–974, Jun. 2011.
- [16] S. Verron, T. Tiplica, and A. Kobi, "Fault Detection with Bayesian Network," 2008.
- [17] T. Han, B. Li, and L. Xu, "A Universal Fault Diagnostic Expert System Based on Bayesian Network," *Int. Conf. Comput. Sci. Softw. Eng.*, vol. 1, 2008.
- [18] S. Renooij and C. Witteman, "Talking probabilities: communicating probabilistic information with words and numbers," *Int. J. Approx. Reason.*, vol. 22, no. 3, pp. 169–194, Dec. 1999.
- [19] M. Azhdari and N. Mehranbod, "Application of Bayesian belief networks to fault detection and diagnosis of industrial processes," in *2010 International Conference on Chemistry and Chemical Engineering*, 2010, no. Iccce, pp. 92–96.
- [20] F. Sahin, M. Ç. Yavuz, Z. Arnavut, and Ö. Uluyol, "Fault diagnosis for airplane engines using Bayesian networks and distributed particle swarm optimization," *Parallel Comput.*, vol. 33, no. 2, pp. 124–143, Mar. 2007.
- [21] G. Chin Jr., S. Choudhury, L. Kangas, S. McFarlane, and A. Marquez, "Fault Detection in Distributed Climate Sensor Networks Using Dynamic Bayesian Networks," *2010 IEEE Sixth Int. Conf. e-Science*, pp. 121–128, Dec. 2010.
- [22] W. Guo, Z. Zhu, and Y. Hou, "A novel fault diagnosis for vehicles based on time-varied Bayesian network modeling," *2011 Chinese Control Decis. Conf.*, pp. 1504–1508, May 2011.
- [23] L. Bennacer, L. Ciavaglia, A. Chibani, Y. Amirat, and A. Mellouk, "Optimization of fault diagnosis based on the combination of Bayesian Networks and Case-Based Reasoning," in *2012 IEEE Network Operations and Management Symposium*, 2012, pp. 619–622.
- [24] R. B. Moreno, "Bayesian modelling of fault diagnosis in mobile communication networks," 2007.
- [25] G. J. Tsinarakis and C. J. Tsinaraki, "OntoMoPS: A modular production system description ontology," *21st Mediterr. Conf. Control Autom.*, pp. 748–753, Jun. 2013.
- [26] J. Li and S. M. Meerkov, *Production Systems Engineering*. Boston, MA: Springer US, 2009.
- [27] M. Bellgran and K. Säfsten, *Production Development*. London: Springer London, 2010.

- [28] M. Bellgran and K. Säfssten, *Production Development*. London: Springer London, 2010.
- [29] B. G. Xu, "Intelligent fault inference for rotating flexible rotors using Bayesian belief network," *Expert Syst. Appl.*, vol. 39, no. 1, pp. 816–822, Jan. 2012.
- [30] R. Squillante and E. Polit, "Diagnóstico e tratamento de falhas críticas em sistemas instrumentados de segurança," 2011.
- [31] J. Cheng, R. Greiner, J. Kelly, D. Bell, and W. Liu, "Learning Bayesian networks from data: An information-theory based approach," *Artif. Intell.*, vol. 137, no. 1–2, pp. 43–90, 2002.
- [32] G. F. Cooper and E. Herskovits, "A Bayesian Method for the Induction of Probabilistic Networks from Data," *Mach. Learn.*, vol. 9, no. 4, pp. 309–347, 1992.
- [33] R. F. Manrique, F. A. Giraldo, and J. S. Esmeral, "Fault detection and diagnosis for wind turbines using data-driven approach," *2012 7th Colomb. Comput. Congr.*, pp. 1–6, Oct. 2012.
- [34] K. Murphy, "bnt - Bayes Net Toolbox for Matlab - Google Project Hosting." [Online]. Available: <https://code.google.com/p/bnt/>. [Accessed: 10-Sep-2014].
- [35] "Tratamiento del agua potable." Canal de Isabel II Gestión, 2012.
- [36] G. OMS., "Guías para la calidad del agua potable," 1995.
- [37] I. Yolanda and A. Cárdenas, "Tratamiento de agua coagulación y floculación," 2000.
- [38] G. Morales Escobar, "Cali en cifras," *Cali Dep. Adm. Planeación*, 2013.
- [39] "MANUAL DE OPERACIÓN DE LA PLANTA DE POTABILIZACIÓN DE AGUA PUERTO MALLARINO." EMCALI EICE-ESP, Cali, pp. 1–279, 2011.