



UNIVERSIDAD DE LOS ANDES
FACULTAD DE INGENIERIA
DOCTORADO EN CIENCIAS APLICADAS
MERIDA – VENEZUELA

**“Desarrollo de un Modelo Inteligente Orientado a
Condiciones de Diagnosticabilidad en Procesos de
Producción”**

Autor: MSc. Rubén J. Leal Tejidor

Tutores: Dr. José L. Aguilar C.

Dr. Addison Ríos Bolívar

**Trabajo de Grado presentado ante la ilustre Universidad de los Andes como
requisito parcial para optar al Título de Doctor en Ciencias Aplicadas**

MÉRIDA, ABRIL 2016

A mis Hijos y Esposa

Cree y lo lograrás...

Napoleón Hill

AGRADECIMIENTOS

El logro de este trabajo es la suma de esfuerzo, fe y dedicación, pero por sobre todo es el resultado de las palabras de aliento y confianza de mis padres

A los Profesores José Aguilar y Addison Ríos por todo el apoyo y los conocimientos que me brindaron para la realización de este proyecto. De igual manera al proyecto FONACIT 2010000307 por su gran apoyo, en conjunto al equipo francés que participó en el mismo, especialmente a la Doctora Louise Travé-Massuyès y al LAAS ([Laboratoire d'analyse et d'architecture des systèmes](#)) en Francia.

Al CDCHTA de la Universidad de Los Andes, a través del proyecto No. I-1302-12-02-B.

A la Universidad de Los Andes por haberme permitido formarme como Doctor en Ciencias Aplicadas.

A todos muchas gracias...

RESUMEN

La presente investigación tiene como objetivo desarrollar un modelo inteligente para el análisis de diagnosticabilidad en procesos de producción, sustentado en la combinación de técnicas de análisis estructural con técnicas de la computación inteligente. En particular, se usaron los Algoritmos Genéticos (AG), para obtener Relaciones de Redundancia Analítica (ARR, por sus siglas en inglés) como mecanismo de análisis de diagnosticabilidad. En tal sentido, usar AG como herramienta para el análisis de selección de sub-conjunto de ecuaciones sensibles a las fallas, posibilita la definición de múltiples objetivos, para evaluar los diferentes aspectos que se deben cumplir para determinar la propiedad de diagnosticabilidad en un sistema. Además, la definición de los individuos es basada en una nueva propuesta de sub-conjunto de ecuaciones con redundancia igual a uno, en función en una ecuación de soporte enmarcada en una falla considerada. Así mismo, la propuesta permite estudiar el problema de localización de sensores en los sistemas que no se puedan determinar las propiedades de detectabilidad o aislabilidad. Por otro lado, el enfoque ha sido aplicado a sistemas de producción continua, en particular a pozos de levantamiento artificial de petróleo por gas, ámbito donde no existen propuestas integradas como la presentada en este trabajo. De esta manera, la propuesta aquí presentada logra cubrir, extender y mejorar las limitantes de los métodos tradicionales utilizados en estos tipos de problemas. Los resultados obtenidos nos permiten concluir que es posible realizar el análisis integrado de un proceso, para estudiar tanto la propiedad de diagnosticabilidad, así como la localización de nuevos sensores en el caso de que no se pueda determinar. Nuestra propuesta es comparada con investigaciones previas sobre análisis de residuos y vinculados al problema de localización de sensores, mostrando en ambos casos resultados satisfactorios. La limitación más importante es a nivel de implantación, ya que requiere de la convergencia de varias áreas (sistemas de diagnóstico de falla, técnicas de computación inteligente, modelos de producción e instrumentación), para poder ser implantado en un entorno real operativo como el caso de estudio.

Palabras Claves: Diagnosticabilidad, Análisis Estructural, Algoritmo Genético, Localización de Sensores, Modelos de producción.

ABSTRACT

This research aims to develop an Intelligent Model for diagnosability analysis of production processes, based on the use of a structural analysis model with intelligent computing techniques. In particular, Genetic Algorithms (GA) was used to obtain Analytical Redundancy Relations as diagnosability analysis mechanism. In this regard, using GA as a tool for fault analysis, allows the definition of multiple objectives, to evaluate the different aspects that must be met to achieve the diagnosability property in a system. Furthermore, the definition of individuals is based on a proposed new proposal of sub-set of equations with redundancy equal to one, based on a support equation by fault. Likewise, the proposal allows studying the problem of sensor placement in systems that do not achieve the detectability or isolability properties. On the other hand, our approach has been applied to continuous production systems, particularly artificial gas lift wells of oil, field where there are not proposals like this research. Thus, our proposal covers, extends and improves the limitations of the traditional methods used in these types of problems. The results allow us to conclude that it is possible to perform an integrated analysis of the production processes, to study both diagnosability property and the placement of new sensors in the case where this property is not reached. Our proposal is compared with previous research about residues analysis based on test support equations, and prior works related to the problem of sensor placement, showing satisfactory results in both cases. The most important limitation is for the implementation, since it requires the convergence of various areas (fault diagnosis systems, intelligent computing techniques, production models and instrumentation) to be implanted in a real operating environment, as the case of study.

Keywords: Diagnosability, Structural Analysis, Sensors Placement, Genetic Algorithm, Production Model.

TABLA DE CONTENIDO

AGRADECIMIENTOS	III
RESUMEN	IV
ABSTRACT	V
ÍNDICE DE FIGURAS	VIII
INDICE DE TABLAS	VIII
ACRONIMOS Y ABREVIATURAS	X
CAPÍTULO I	1
GENERALIDADES	1
1.1. INTRODUCCIÓN.....	1
1.2. ANTECEDENTES	3
1.3. PLANTEAMIENTO DEL PROBLEMA	9
1.4. OBJETIVOS.....	12
1.5. ALCANCE	13
1.6. ACTIVIDADES DOCTORALES DESARROLLADAS DURANTE LA TESIS	14
1.7. ORGANIZACIÓN DE LA INVESTIGACIÓN	15
CAPÍTULO II	17
MARCO TEORICO	17
2.1. DIAGNÓSTICO.....	17
2.2. DIAGNOSTICABILIDAD	24
2.2.1. <i>DIAGNOSTICABILIDAD BASADOS EN MODELOS</i>	25
• <i>Observadores</i>	28
• <i>Espacios de paridad</i>	30
• <i>Filtros Kalman</i>	31
2.3. TÉCNICAS INTELIGENTES.....	33
2.3.1. <i>ALGORITMO GENÉTICO</i>	33
2.4. MÉTODO DE EXTRACCIÓN DE CRUDO.....	39
2.4.1. <i>EXTRACCIÓN DE PETRÓLEO POR INYECCIÓN DE GAS</i>	41
2.4.2. <i>VENTAJA, DESVENTAJAS Y APLICACIONES DEL SISTEMA LAG</i>	43
2.4.3. <i>MODELO DE UN SISTEMA LAG</i>	44
2.5. INTERRELACIÓN ENTRE LOS TEMAS TRATADOS EN LA INVESTIGACIÓN	46
CAPÍTULO III	48

ANÁLISIS ESTRUCTURAL PARA DETERMINAR LAS PROPIEDADES DE DIAGNOSTICABILIDAD	48
3.1. ANÁLISIS ESTRUCTURAL	48
3.1.1. MATRIZ ESTRUCTURAL	48
3.1.2. GRAFO BIPARTITO	50
3.2. DESCOMPOSICIÓN CANÓNICA DE UN SISTEMA	50
3.3. EMPAREJAMIENTO	54
3.4. RELACIONES DE REDUNDANCIA ANALÍTICA	55
3.5. MATRIZ DE FIRMA DE FALLAS	60
3.6. LOCALIZACIÓN DE SENSORES	64
3.7. ANÁLISIS DE DIAGNOSTICABILIDAD CON MÉTODOS FDI PARA PROCESOS CONTINUOS. ..	67
3.7.1. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN PROCESO CONTINUO	67
3.7.2. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN POZO LAG CON DOS FALLAS.....	68
3.7.3. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN POZO LAG CON CINCO FALLAS	76
3.8. LOCALIZACIÓN DE SENSORES EN UN SISTEMA NO LINEAL	77
3.8.1. LOCALIZACIÓN DE SENSORES BASADA EN TRABAJOS PREVIOS	77
CAPÍTULO IV	79
MODELO INTELIGENTE PARA EL ANÁLISIS DE DIAGNOSTICABILIDAD	79
4.1. ALGORITMOS PRINCIPALES DEL MODELO	80
4.2. ALGORITMOS GENÉTICOS USADOS PARA EL ANÁLISIS DE DIAGNOSTICABILIDAD	83
4.2.1. AG1 PARA ENCONTRAR POBLACIÓN DE MSOS	83
4.2.2. AG2 PARA EL ANÁLISIS DE DETECTABILIDAD Y AISLABILIDAD	89
4.3. AG3 PARA LOCALIZACIÓN DE SENSORES	95
4.4. METODOLOGÍA PARA USAR LOS AG EN CASOS REALES	98
4.5. ANÁLISIS DE DIAGNOSTICABILIDAD BASADO EN EL MODELO INTELIGENTE PARA SISTEMAS CONTINUOS.	100
4.5.1. ANÁLISIS DE DIAGNOSTICABILIDAD CON AG EN UN SISTEMA CONTINUO.....	100
4.5.2. ANÁLISIS DE DIAGNOSTICABILIDAD CON AG EN UN POZO LAG CON DOS FALLAS	103
4.5.3. ANÁLISIS DE DIAGNOSTICABILIDAD CON AG EN UN POZO LAG CON CINCO FALLAS.....	107
4.6. LOCALIZACIÓN DE SENSORES BASADA EN EL MODELO INTELIGENTE	109
4.6.1. LOCALIZACIÓN DE SENSORES CON AG.....	109
4.6.2. LOCALIZACIÓN DE SENSORES CON AG EN UN POZO LAG	110
4.7. COMPARACIÓN DE LOS RESULTADOS	114
CAPÍTULO V	117
CONCLUSIONES Y TRABAJO FUTURO	117

5.1. CONCLUSIONES.....	117
5.2. TRABAJOS FUTURO.....	120
BIBLIOGRAFÍA	122

ÍNDICE DE FIGURAS

FIGURA 2.1 -MÉTODOS DE DIAGNÓSTICO DE FALLAS.	21
FIGURA 2.2- SISTEMA GENERADOR DE RESIDUOS UTILIZANDO MBD.....	26
FIGURA 2.3 - SISTEMA DE EVALUADOR DE RESIDUO.	27
FIGURA 2.4 -ESQUEMA DE PRODUCCIÓN.	40
FIGURA 2.5 -MODELO LEVANTAMIENTO ARTIFICIAL POR GAS.	42
FIGURA 2.6 -MODELO DE COMPORTAMIENTO DE UN POZO PRODUCIENDO CON UN MÉTODO DE INYECCIÓN DE GAS.	43
FIGURA 3.1 -GRAFO BIPARTITO.	50
FIGURA 3.2 - GRAFO BIPARTITO DEL EJEMPLO ANTERIOR.	67
FIGURA 3.3- COMPORTAMIENTO DEL POZO EN ESTADO NORMAL.....	71
FIGURA 3.4- MATRIZ INCIDENCIA CON 2 FALLAS.....	72
FIGURA 3.5 -ANÁLISIS DE RESIDUOS EN ESTADO NORMAL.	73
FIGURA 3.6- ANÁLISIS DE RESIDUOS CON F_1 ACTIVA.....	74
FIGURA 3.7- ANÁLISIS DE RESIDUOS CON F_2 ACTIVA.....	75
FIGURA 3.8- ANÁLISIS DE RESIDUOS CON F_1 Y F_2 ACTIVAS.	75
FIGURA 3.9- MATRIZ DE INCIDENCIA PARA EL ANÁLISIS DE CINCO FALLAS.	76
FIGURA 3.10 - MATRIZ DE INCIDENCIA PARA EL ANÁLISIS DE LAS CINCO FALLAS.....	78
FIGURA 4.1 - EJEMPLO DE UN GRAFO BIPARTITO.	84
FIGURA 4.2- ESTRUCTURA DEL MODELO EN AG1 PARA LA FIGURA 4.1.	84
FIGURA 4.3 - POSIBLE INDIVIDUO C1 PARA AG1.	84
FIGURA 4.4- ESTRUCTURA DE UN INDIVIDUO DEL AG2, PARA EL EJEMPLO DE LA FIGURA 3.1.	91
FIGURA 4.5 -POSIBLE MODIFICACIÓN DE MODELO DE LA FIGURA 3.2.....	97
FIGURA 4.6- GRAFO BIPARTITO DEL EJEMPLO ANTERIOR.....	109
FIGURA 4.7 -MATRIZ DE INCIDENCIA DEL SISTEMA LAG CON	111
FIGURA 4.8 -MATRIZ DE INCIDENCIA DEL SISTEMA LAG RESULTADO DE LA EJECUCION DEL AG3	114

INDICE DE TABLAS

TABLA 3.1-MATRIZ ESTRUCTURAL O MATRIZ DE BIADJACENCIA.....	49
TABLA 3.2-MATRIZ ESTRUCTURAL CON SOLO VARIABLES DESCONOCIDAS.....	49
TABLA 2.4-MATRIZ ESTRUCTURAL DE UN SUB-CONJUNTO DE MSOS.....	55
TABLA 3.4-MATRIZ ESTRUCTURAL DEL MSOS1.	59
TABLA 2.5-MATRIZ ESTRUCTURAL DEL MSOS2.	60
TABLA 3.6 -MATRIZ DE FIRMA DE FALLAS.	61
TABLA 3.7-MATRIZ DE FIRMA DE FALLAS.	62
TABLA 3.8- CONJUNTO DE MTES PROPUESTO POR EL ALGORITMO DESARROLLADO EN [21].	68
TABLA 3.9- MATRIZ DE FIRMA DE FALLAS RESULTADO DEL ALGORITMO DESARROLLADO EN [21].	68
TABLA 3.10- COEFICIENTES CONSTANTES.....	70
TABLA 3.11- MATRIZ DE FIRMA DE FALLAS CON 2 FALLAS.....	73
TABLA 3.12- MATRIZ DE FIRMA DE FALLAS PARA EL ANÁLISIS DE CINCO FALLAS.	77
TABLA 3.13- MATRIZ DE FIRMA DE FALLAS PARA EL ANÁLISIS DE LAS CINCO FALLAS.....	78

TABLA 4.1 - REPRESENTACIÓN DEL INDIVIDUO DE LA FIGURA 4.3.....	84
TABLA 4.2 - CRITERIO DE LA OPTIMIZACIÓN.	86
TABLA 4.3 - COEFICIENTE DE LOS PESOS.....	86
TABLA 4.4 -POBLACIÓN DE POSIBLES MSOS PARA LA FIGURA 41.	90
TABLA 4.5 - $MS1$ MFF SIN LA $f1$	92
TABLA 4.6 – POSIBLES COMBINACIONES $Mcomb1$ PARA LA COMPARACIÓN CON $f1$	92
TABLA 4.7 - $Mk'1$ COMBINACIONES DE fk MFF SIN LA $f1$	93
TABLA 4.8- POBLACIÓN DE POSIBLES INDIVIDUOS PARA EL EJEMPLO DE LA TABLA 4.4.....	93
TABLA 4.9- EVALUACIÓN DE O^1 PARA LOS INDIVIDUOS DE LA TABLA 4.8.	93
TABLA 4.10- EVALUACIÓN DE O^2 PARA LOS INDIVIDUOS DE LA TABLA 4.8.	93
TABLA 4.11 - MATRIZ DE FIRMA DE FALLA PARA A_2	94
TABLA 4.12 - REPRESENTACIÓN DE UN INDIVIDUO EN LA POBLACIÓN DEL AG3 A PARTIR DE G	97
TABLA 4.13- REPRESENTACIÓN DEL INDIVIDUO DEL MODELO DE LA FIGURA 3.2.	101
TABLA 4.14- CONJUNTOS DE MSOS GENERADOS POR LOS AG.	102
TABLA 4.15- MFF GENERADO POR AG2.	102
TABLA 4.16- REPRESENTACIÓN DEL INDIVIDUO DE UN POZO LAG CON DOS FALLAS.	103
TABLA 4.17- EVALUACIÓN DE LA POBLACIÓN INICIAL PARA EL ESTUDIO DE $f1$	103
TABLA 4.18- EVALUACIÓN DE LA POBLACIÓN FINAL PARA EL ESTUDIO DE $f1$	105
TABLA 4.19- POBLACIÓN DE MSOS PARA $f1$ Y $f2$	106
TABLA 4.20- MSOS SELECCIONADO POR AG2 PARA CADA FALLA.	106
TABLA 4.21- MFF RESULTANTE DE AG2 CON $f1$ Y $f2$	107
TABLA 4.22 - REPRESENTACIÓN DEL INDIVIDUO DE UN POZO LAG CON CINCO FALLAS.....	107
TABLA 4.23- POBLACIÓN DE MSOS CONSEGUIDAS POR AG1 PARA LAS 5 FALLAS.	108
TABLA 4.24- MFF PARA EL ANÁLISIS DE CINCO FALLAS, USANDO	109
TABLA 4.25 - MFF RESULTADO DEL ALGORITMO DE LOCALIZACIÓN PROPUESTO.	110
TABLA 4.26- MFF RESULTADO DEL ANÁLISIS CON SOLO CUATRO VARIABLES MEDIDAS.....	112
TABLA 4.27 -MFF RESULTADO DEL AG3 PROPONRIENDO UN SENSOR EN $GLDP$	113
TABLA 4.28-MFF RESULTADO DEL AG3 PROPONRIENDO UN SENSOR EN GLP	113
TABLA 4.29-MFF RESULTADO DEL AG3 PROPONRIENDO UN SENSOR EN W_{GC}	113

ACRONIMOS Y ABREVIATURAS

$ A $	Sea A un conjunto $ \cdot $ es la Cardinalidad del conjunto
$A_i = \{A_1, \dots, A_p\}$	Define el conjunto de la variable A donde i va desde 1 hasta p
ARR	Relaciones de Redundancia Analítica
AG	Algoritmos Genéticos
A_r	Área transversal de la tubería por debajo del punto de inyección en un pozo LAG
A_t	Área transversal de la tubería por encima del punto de inyección en un pozo LAG
BES	Bombeo Electro-sumergible
BCP	Bombeo de Cavidad Progresiva
BNPD	Barriles neto de producción diaria
BM	Bombeo Mecánico por varilla de succión
BH	Bombeo Hidráulico
C	Individuo en el AG1
C_{iv}	Constantes de compresibilidad de flujo de gas en un pozo LAG
C_o	Constantes de compresibilidad de flujo mixto en un pozo LAG
C_r	Constantes de compresibilidad de flujo petróleo en el fondo en un pozo LAG
DX	Diagnosis Community
Ec	Emparejamiento Completo
Ep	Emparejamiento
f	Falla en el modelo del sistema
FF	Función objetivo del AG
FDI	Fault Diagnosis and Isolation
glp	Presión del sistema proveniente de plantas compresoras en un pozo LAG
$gldp$	Presión diferencial medida a través de una placa orificio en un pozo LAG
Q_{iny}	Flujo de Gas de Levantamiento en un pozo LAG
Q_{prod}	Tasa de producción en un pozo LAG
L_r	Longitud desde el fondo del pozo hasta el punto de inyección de gas en un pozo LAG
L_t	Longitud de la tubería en un pozo LAG
LAG	Levantamiento Artificial por Gas
M	Modelo de un sistema
M^-	Parte Sub-determinada en un Modelo
M^0	Parte Justamente-determinada en un Modelo
M^+	Parte Sobre-determinada en un Modelo
M_0	Peso molecular del gas en un pozo LAG
M_{NF}	Modelo del sistema en Modo normal (Libre de falla)
M_F	Modelo del sistema en presencia de una falla)
MBD	Diagnóstico basado en modelos

MFF	Matriz de firma de fallas
MPCDG	Miles de pie cúbico de gas por día
MSO	Mínimo Sistema Sobre-determinado
MSOS	Mínimo Sistema Sobre-determinado con Soporte
MTES	Mínima Ecuación de Soporte de prueba
P_{ai}	Presión en el anular en un pozo LAG
$\rho_{a,inj}$	Densidad del gas en el anular en el punto de inyección en un pozo LAG
ρ_m	Densidad de la mezcla de petróleo/gas en un pozo LAG
ρ_o	Densidad del petróleo en un pozo LAG
P_s	Presión en el separador en un pozo LAG
P_t	Presión en la parte superior de la tubería en un pozo LAG
$P_{t,b}$	Presión en la parte inferior de la tubería tubería en un pozo LAG
$P_{t,inj}$	Presión en la tubería en el punto de inyección de gas en un pozo LAG
P_r	Presión en el reservorio
\mathbb{R}	Conjunto de números reales
R	Residuo
R	Constante del gas en un pozo LAG
SO	Sistema Sobre-determinado
T_a	Temperatura en el anular en un pozo LAG
T_t	Temperatura en la tubería en un pozo LAG
TES	Ecuación de Soporte de prueba
$a \in \mathbb{R}^w$	Vector a de orden w con entradas reales
v_o	Volumen específico del petróleo en un pozo LAG
w_{iv}	Tasa de flujo másico de gas desde el anular hacia el tubing en un pozo LAG
w_{gc}	Tasa de flujo másico de gas inyectado en el anular en un pozo LAG
w_p	Flujo másico mezclado en la tubería de producción en un pozo LAG
w_{pg}	Flujo másico de gas a través de la válvula de choke de producción en un pozo LAG
w_{po}	Flujo másico de petróleo a través de la válvula de choke en un pozo LAG
w_r	Flujo másico de petróleo proveniente del reservorio por el tubing en un pozo LAG
x	Variable desconocida del modelo del sistema
\hat{x}	Estimada de la variable desconocida del modelo del sistema
x_1	Flujo de masa de gas en el anular en un pozo LAG
x_2	Flujo de masa de gas en la tubería en un pozo LAG
x_3	Flujo masa de petróleo en el tubing en un pozo LAG
\dot{x}	Variable derivada desconocida en el modelo del sistema
y	Variable conocida del modelo en el sistema
\hat{y}	Estimada de la variable conocida del modelo del sistema
\bar{y}	Conjunto de variable conocida y todas sus derivadas hasta un orden desconocido
\mathcal{M}	Sub modelo estructural
Υ	Aristas en un grafo Bipartito
φ	Grado de redundancia en un sub-conjunto de ecuación en un modelo

CAPÍTULO I GENERALIDADES

1.1. INTRODUCCIÓN

En el transcurso del siglo XXI, la demanda en confiabilidad y seguridad de los procesos industriales es cada vez más exigente. En ese sentido, se requiere de cuantiosas inversiones en recursos físicos y humanos, con el fin de desarrollar soluciones que ayuden a minimizar las ocurrencias de fallas y sus consecuencias en los sistemas de producción. En particular, existe la necesidad de diseñar y construir sistemas de diagnóstico integral en los procesos de producción, considerando sus componentes, representado en modelos estructurales de los mismos, analizando la propiedad de diagnosticabilidad en ellos, entre otros aspectos.

Este documento presenta la propuesta de un “Modelo Inteligente orientado a condiciones de diagnosticabilidad en procesos de producción”, basado en un modelo estructural y en técnicas de la computación evolutiva, en específico los AG. Particularmente, se propone un modelo estructural basado en el análisis de los procesos de producción, específicamente para procesos de extracción de petróleo por inyección de gas.

Con el propósito de desarrollar dicho modelo, en este trabajo se abordan aspectos vinculados al diagnóstico mediante el estudio de las relaciones de redundancias y las funciones residuos en los sistemas. Los mismos son analizados para resolver el problema de diagnosticabilidad. Igualmente, se estudia en esta investigación el uso de los AG en el análisis de la diagnosticabilidad, en particular en sus propiedades de base, de detectabilidad y aislabilidad de fallas, en particular en sistemas continuos.

Es menester acotar que actualmente existen varios estudios de análisis de diagnosticabilidad basados en redundancia analítica bajo modelos estructurales de los procesos [1, 2, 3]; sin embargo, en ocasiones es complicado realizar un exhaustivo análisis de las redundancias, sobre todo cuando se desea discernir entre las fallas consideradas, producto de la gran cantidad de información generada. Esto es especialmente importante cuando el número de fallas es grande, cuando se genera información con similares características, o cuando los modelos del proceso bajo estudio son complejos. También, en el tema de localización de sensores existen varias propuestas en la literatura [4, 5], donde utilizan AG para la localización de sensores en función a ARR, pero el análisis se hace complejo al momento de analizar posteriormente los residuos, por la gran cantidad de información que estos pueden generar. Existen otras propuestas para el problema de optimización de la localización de sensores en la fase de diseño en [6, 7, 8, 9]; sin embargo, tienen limitaciones en cuanto a la calidad de la información resultante del análisis, al arrojar como resultados una gran cantidad de residuos, dificultando el análisis de aislabilidad. Además, en las mismas no se incluyen costos de implantación o análisis de la calidad de los residuos resultantes.

La presente investigación surge por la necesidad de implementar modelos inteligentes que permitan analizar el diagnóstico de fallas en los sistemas de producción en el ámbito petrolero. En particular, se requiere de sistemas que permitan analizar, de una forma más amplia, los posibles problemas de fallas en los procesos de producción, para lo cual se requiere de sistemas de diagnóstico integral, que diagnostiquen no solamente las fallas presentes en un proceso de producción en un momento dado, sino que vayan más allá. En ese sentido, en este proyecto se propone desarrollar un modelo de diagnosticabilidad integral para procesos de producción petrolera, de tal manera, analizar esta propiedad, además de donde incorporar nuevos sensores si la misma no se distinga.

Así, la propuesta de un Modelo Inteligente orientado a condiciones de diagnosticabilidad en procesos de producción, es un aporte teórico-práctico, innovador para el análisis de las fallas en los procesos de extracción de petróleo por inyección de gas. Por

otro lado, la posibilidad de analizar la localización de sensores en el modelo integral para incrementar la observabilidad del proceso, basado en los costos de implantación de los nuevos sensores en el sistema, le confieren características únicas a la propuesta.

En concreto, uno de los aportes fundamentales de la investigación, es la definición de un modelo para el análisis de redundancias en un sistema utilizando las técnicas de modelos estructurales. Dicho modelo enfatiza la redundancia basada en una ecuación que permite conocer el origen de la falla (donde se encuentra presente). Además, el modelo se caracteriza por minimizar la redundancia a su menor grado para un mejor análisis, utilizando técnicas computacionales inteligentes para resolver el problema combinatorio de selección entre la diversidad de opciones, y así, dar solución eficiente al conjunto de fallas consideradas, muy común en los grandes y complejos procesos de producción. Otro aporte fundamental en el modelo, es que permite determinar la ubicación de nuevos sensores, que posibilitan incrementar la cantidad de variables medidas, y por ende, incrementar las ARR, enmarcadas en ecuaciones de soporte de prueba donde inciden directamente las fallas consideradas en un proceso. Finalmente, otro aporte de este trabajo, es la integración de estos estudios en un solo Modelo Inteligente, con capacidad de asegurar el análisis de diagnosticabilidad en procesos de producción continuos.

1.2. ANTECEDENTES

Todo sistema físico, sin excepción, está sujeto a cambios en los parámetros operacionales, lo cuales modifican el comportamiento para el cual fueron diseñados. Bajo este contexto, los cambios fuera de los límites de tolerancia para los cuales fueron establecidos, de acuerdo a los criterios de ingeniería, serán considerados como fallas en el presente trabajo. En tal sentido, la detección rápida de la presencia de las fallas en los sistemas, puede ayudar a tomar acciones correctivas reduciendo el daño potencial que éstas puedan ocasionar; para ello, es indispensable realizar un diagnóstico de fallas que permita detectar los cambios en el comportamiento, e incluso identificarlos.

En este orden de ideas, el diagnóstico de fallas se puede abordar desde múltiples metodologías, algunas provenientes de la comunidad de control conocidas como FDI (Fault Diagnosis and Isolation por sus siglas en inglés), otras metodologías son basadas en inteligencia artificial utilizadas por la comunidad conocida como DX (Diagnosis Community por sus siglas en inglés). Un modelo de diagnóstico de sistemas complejos es propuesto en [10, 11], los cuales son modelos híbridos propuestos entre las comunidades FDI y DX, y basan sus aproximaciones en la teoría de control, en modelos matemáticos de los procesos, y en modelos basados en la inteligencia artificial. En [10] también comparan los enfoques propuestos por las dos comunidades, concluyendo que con cualquiera de las dos se logran obtener los resultados esperados. Para el desarrollo de esta investigación se utilizó un enfoque de la comunidad FDI propuesto en [2, 3, 12, 13], específicamente, basado en modelos estructurales, para el diseño de un sistema de análisis de diagnosticabilidad en procesos de producción.

Es necesario aclarar que la diagnosticabilidad es la propiedad de determinar si todas las fallas consideradas en un sistema son detectables y aislables unas de otras. En [3] se presenta un estudio de diagnosticabilidad de fallas en sistemas dinámicos, allí se analizan dos técnicas de diagnóstico basadas en modelos; la primera se fundamenta en el análisis estructural para localizar los sensores necesarios que conlleven al máximo grado de diagnosticabilidad, la segunda utiliza la representación en espacio de estado de modelos discretos para identificar los sensores que permiten la discriminación de los fallos. En [14] se introduce un concepto de diagnosticabilidad para sistemas de control híbrido: un sistema se puede diagnosticar si es posible detectar un fallo dentro de un tiempo finito, solo con salidas observables del sistema.

Algunos trabajos previos han modelado la diagnosticabilidad para procesos continuos basados en aproximaciones FDI [15, 16], donde el principio básico consiste en comparar el comportamiento actual del sistema con un modelo analítico de referencia, el cual representa el comportamiento normal, con la finalidad de que cuando el sistema se encuentre bajo la presencia de una falla, la diferencia entre los mismos generará residuos sensibles a las fallas.

Existen diversas metodologías para obtener la relación entre las fallas y el diagnóstico del sistema [17]. Algunas de ellas se basan en el conocimiento de expertos [18]. En particular, al hacer procesos de ingeniería de conocimiento, es posible obtener una representación basada en reglas del proceso de diagnóstico, muy útil cuando es difícil obtener un modelo analítico de un sistema dada su complejidad matemática. Con estas técnicas, el diagnóstico se realiza mediante la comparación de la evolución del sistema con las clases definidas por las reglas.

En [1, 12, 15, 16, 19] realizan estudios para la generación de residuos mediante la técnica de relaciones de redundancia analítica (ARR por sus siglas en inglés), las cuales utilizan un conjunto de ecuaciones que caracterizan el modelo físico del sistema, en donde la principal característica es que la cardinalidad del conjunto de las ecuaciones debe ser mayor que la cardinalidad del conjunto de las variables desconocidas en el sistema, de manera que pueda existir redundancia, con el fin de eliminar los estados desconocidos del sistema. Esto permite obtener las ARR, las cuales son ecuaciones compuestas únicamente por variables medidas o conocidas, en ausencia de fallas.

Asimismo, un paso esencial en el diseño de un sistema de diagnóstico basado en modelos, es encontrar un conjunto de generadores de residuos que permitan la detección y el aislamiento de las fallas. Bajo este contexto, para ser capaz de encontrar un buen conjunto de relaciones de redundancia que se transformen en residuos, es necesario que el método utilizado para la generación de residuos dé como resultado las ecuaciones analíticas, necesarias para comprobar la consistencia de las mediciones de un modelo dado. Basado en ello, en [20] se presenta un método de generación de residuos, el cual se basa en el cálculo de variables desconocidas de acuerdo a una secuencia de cómputo finito. Para ello, se utilizan las propiedades analíticas de las ecuaciones del modelo, así como herramientas para la resolución de ecuaciones algebraicas. De igual modo, [19] describe el cálculo analítico de los generadores de residuos, para obtener la ecuación analítica redundante que verifica si el sub-conjunto de ecuaciones encontrada es consistente con el modelo del sistema.

En particular, en la presente investigación se hace necesario identificar los diferentes modelos estructurales para el análisis de diagnosticabilidad en el ámbito de procesos continuos, como en [21, 22, 23], para adecuarlos, y así realizar un análisis orientado a procesos de extracción de petróleo [24], utilizando un diagnóstico basado en modelos para determinar las fallas ocurridas en los sistemas, brindando la oportunidad de tomar acciones oportunas sobre las mismas y mantener la disponibilidad de la producción.

Para el Diagnóstico Basada en Modelos MBD (Model-Based Diagnosis por sus siglas en inglés), la construcción del sistema de diagnóstico hace hincapié en tener un modelo del proceso. En el caso de grandes y complejos sistemas, se han propuesto aproximaciones estructurales [12, 22, 25, 26], en donde solo se busca la relación entre variables y ecuaciones y no su composición analítica. Estas aproximaciones estructurales se pueden analizar desde el ámbito de grafos bipartitos o matrices de incidencia, disminuyendo la dificultad para el análisis de los modelos de los sistemas.

Por su parte, en [27] se muestra un algoritmo de diagnóstico para sistemas continuos, el cual analiza la estructura de un sistema, detectando la redundancia en porciones usando el enfoque ARR; dicho método es usado para analizar el comportamiento de un motor diésel como caso de estudio. En [27] introducen la noción de sub-sistemas mínimo sobre determinados MSO (Minimal Structurally Over-determined por sus siglas en inglés), el cual consiste en obtener ARR con la menor redundancia posible. El análisis se basa la descomposición canónica del sistema mediante la metodología de Dulmage-Mendelsohn [23] dividiendo el sistema en tres parte, una parte sub-determinada con menos ecuaciones que variables desconocidas M^- , una parte estructuralmente-determinada con igual cantidad de ecuaciones que variables desconocidas M^0 , y una tercera parte sobre-determinada del sistema con más ecuaciones que variables desconocidas M^+ , con el fin de obtener redundancias que permitan realizar un buen análisis de diagnosticabilidad, donde M es el modelo del sistema.

Ese enfoque se desarrolla más a fondo en [20, 21]. Dado que el número de MSO crece exponencialmente según el grado de redundancia, hace que la tarea de calcular MSO

sea casi intratable para los sistemas con alto grado de redundancia, y más aún, determinar cuál redundancia favorece al análisis. En [21] se describe un algoritmo que incluye información para calcular un sub-conjunto similar a los MSO, introduciendo la información acerca de los errores puntuales, destacados o de mayor importancia para los usuarios del proceso, el cual es llamado ecuaciones mínimas de soporte MTES (Minimum Test Equation Support, por sus siglas en inglés). Una diferencia clave, en comparación con un enfoque basado en MSO, es que se toma en cuenta la influencia de los fallos, y el número resultante de los sub-modelos comprobables es menor, así como la complejidad computacional para la búsqueda de ellos se reduce significativamente, sin desmejorar el posible rendimiento del diagnóstico. Ellos muestran que el MTES caracteriza la propiedad de aislabilidad de múltiples fallas en un modelo.

Como se indicó previamente, varios algoritmos para el cálculo de ARR en sistemas sobre-determinados se han propuesto [21, 27]. Sin embargo, todos estos algoritmos tienen problemas de complejidad al intentar ser usados en casos industriales que contienen dinámicas que se representan por combinaciones de ecuaciones diferenciales y algebraicas, lo cual dificulta la obtención de residuos. Por tal motivo, se deben realizar aproximaciones para la generación de residuos como ha sido propuesto en [20].

Por otra parte, la eficiencia de un diagnóstico y la localización de un sensor se pueden medir por el grado de diagnosticabilidad que proporcionan. Sin embargo, el mismo nivel de diagnosticabilidad puede obtenerse para diferentes configuraciones de sensores. En algunos casos, el nivel más alto de diagnosticabilidad podría no ser necesario. En [4] se propuso un AG para la localización de sensores, para el análisis de diagnosticabilidad del sistema. También, en [11] se combina el uso de la inteligencia artificial con esquemas de aproximaciones estructurales FDI.

Por otro lado, en [6] se propone el desarrollo de un algoritmo para el cálculo de la localización de sensores cumpliendo con los requisitos de detectabilidad y aislabilidad de fallas, utilizando la metodología de análisis de modelos estructurales. La técnica aborda la sensibilidad que tienen las fallas en una ecuación analítica en el modelo del sistema,

llamándola ecuación de soporte de prueba. En [7], la detectabilidad y la aislabilidad son evaluadas para un modelo diferencial-algebraico lineal. Allí se supone que la sensibilidad de una falla está en función de una ecuación física del sistema, donde es posible obtener localizaciones de sensores, debido a que el algoritmo proporciona las soluciones que maximizan la determinación de las propiedades localizando sensores en función a estas ecuaciones. En particular, este algoritmo es usado para compararlo con el enfoque inteligente propuesto en este trabajo, así que es implantado en el caso de estudio.

En [8, 9] realizan un análisis de localización de sensores utilizando AG, sin embargo, los resultados son en función a ARR de los sistemas, obteniendo resultados muy imprecisos. Este trabajo realiza las aproximaciones en función a las mínimas relaciones de redundancia afectadas por una falla, tendiendo a uno el grado de la redundancia por falla considerada, haciendo los resultados más precisos. Además, involucra en la función de evaluación el costo de la implantación de los nuevos sensores, para elegir aquellas propuestas que no solo logren determinar las propiedades de detección y aislabilidad, sino también que cumplan con el criterio de menor costo.

En cuanto al caso de estudio considerado en este trabajo, el levantamiento de petróleo en pozos por inyección de gas (*Gas lift well*) [28, 29], existen varios trabajos que se han dedicado a estudiarlo. Por ejemplo, en [30] muestran un modelo matemático del proceso utilizando ecuaciones físicas que rigen el proceso de este método de extracción de petróleo, en el cual se pueden identificar ecuaciones de soporte. A su vez, en [31] realizan un estudio de instrumentación inteligente para mejorar la producción de petróleo en un pozo. Finalmente, en [32] realizan un modelo inteligente para la supervisión de la producción de un pozo mediante la inyección continua de gas. Dicho modelo se basa en técnicas de análisis nodal y balances de masas. Existen otros trabajos vinculados al control automático y al diagnóstico de fallas en los procesos de levantamiento de petróleo en pozos por inyección de gas, como son [33, 34, 35, 36].

1.3. PLANTEAMIENTO DEL PROBLEMA

Los procesos de producción requieren una supervisión, además del control constante, de sus operaciones y de las instalaciones asociadas. La industria de petróleo (pozos, estaciones de flujo, múltiples de gas, entre otros) no escapa de la necesaria supervisión de los procesos internos, para mantener el funcionamiento del mismo. El caso de estudio es el de producción de petróleo por inyección de gas de levantamiento, el cual es un proceso continuo. Por la importancia de los pozos de petróleo basados en inyección de gas para la industria petrolera, sobre todo en Venezuela [33], es que en este contexto se enmarca este trabajo.

En general, tanto el personal de operación como de mantenimiento, así como los sistemas de supervisión, son los encargados de monitorear, identificar y resolver los problemas que afectan el estado normal de operación de un proceso de producción. Estas tareas, las realizan utilizando e interpretando la información proporcionada por las herramientas tradicionales con las que cuenta dicho proceso, como los sistemas de alarmas, los despliegues gráficos, los registros históricos de señales y de eventos de los sistemas de control y adquisición de datos, entre otros. Frecuentemente, el personal se enfrenta a un problema; el cual se presenta al momento de interpretar toda esta información, debido a que llega muy rápido, en gran cantidad, y en algunos casos, sin indicar la causa de origen del problema, pero quizás lo más complicado de todo, es que cuenta con poco tiempo para responder adecuadamente. Todo esto provoca que el proceso para realizar un diagnóstico correcto del problema se vuelva difícil y complejo [37, 38, 39].

Bajo este contexto, la dificultad que se tiene para realizar un diagnóstico correcto de fallas en un proceso de producción, se debe a que las herramientas disponibles tienen capacidades limitadas. Por ejemplo, los sistemas de alarmas indican la presencia de condiciones anormales, pero no explican la razón de dicha condición. Los datos históricos tienen la capacidad de indicar la secuencia en que ocurrieron ciertos eventos, pero no indican la causa; o por otro lado, la falta de disponibilidad de estos datos en

ocasiones no permite obtener un buen diagnóstico. Con el análisis basado en modelos de los procesos, se puede realizar una interpretación del comportamiento anormal del proceso en estudio [39]. Con los modelos, se realiza una representación del proceso usando la información que describe las actividades que se llevan a cabo en él.

Una forma de contribuir a las tareas de supervisión de los procesos de producción consiste en utilizar técnicas de diagnóstico de fallas, las cuales analicen los cambios producidos en el comportamiento de los componentes del proceso. Pero, para el uso de tales técnicas de diagnóstico, es fundamental determinar la propiedad de diagnosticabilidad disponible en un proceso, para estudiar aspectos como la detectabilidad y la aislabilidad de sus fallas [1]. Si esas propiedades no pueden ser determinadas en un proceso, sus fallas no podrán ser detectables, o bien no se podrá discernir entre aquellas que son detectables. Es por este motivo, que ha aumentado el interés en el análisis de diagnosticabilidad de los sistemas [15].

En el presente trabajo se desarrolla un modelo inteligente para el análisis de diagnosticabilidad que aborda el problema de diagnóstico basado en modelos, combinándolos con técnicas de la computación inteligente, en específico los algoritmos genéticos. El modelo inteligente está fundamentado en tres partes:

- La primera parte del modelo propuesto está basado en modelos estructurales de sistemas continuos, por lo cual se define el problema de optimización combinatoria de generación de residuos usando la técnica ARR [1, 12], el cual es resuelto usando AG.
- En la segunda parte del modelo se plantea un problema de optimización combinatoria multi-objetivo usando AG, tal y como es realizado en [2, 12], para evaluar las propiedades de diagnosticabilidad (detectabilidad y aislabilidad) en el sistema. Para ello se construye la Matriz de Firma de Fallas del problema bajo estudio.

- La tercera parte del modelo consiste en un análisis basado en AG que permite determinar la localización de sensores, en el caso de que en el sistema no se pueda determinar las propiedades de detección y aislamiento de fallas. Además, realiza un análisis de costos de implantación.

El uso de un modelo estructural es más apropiado que el modelo explícito del proceso, debido a que en los modelos explícitos las ecuaciones y variables están conectadas mediante expresiones analíticas y parámetros precisos. Así mismo, un modelo estructural solo establece la relación existente entre variables y ecuaciones (si existe o no). En particular, el presente trabajo propone un modelo estructural para el caso de un pozo de extracción de petróleo con levantamiento artificial de gas, como caso particular, el cual puede ser generalizado para procesos continuos, basado en los algoritmos propuestos en [21, 27]; además, se construye un generador de residuos para evaluar el comportamiento de los ARR resultantes, como en [19].

Un análisis de diagnosticabilidad en un proceso de producción continuo puede arrojar como resultados una gran cantidad de redundancias analíticas, por tal motivo, este trabajo fusiona la técnica de análisis estructural del proceso, expresado mediante teoría de grafos bipartidos, con técnicas inteligentes, para optimizar la selección de ARRs que aseguren evaluar la propiedad de diagnosticabilidad. Particularmente, esto plantea un problema de optimización combinatoria para el análisis estructural, el cual consiste en obtener el emparejamiento óptimo de variables en un grafo bipartito que modela la relación entre las ecuaciones y las variables del sistema, el cual es resuelto usando AG.

La evaluación de las propiedades de detectabilidad y aislabilidad en un conjunto de residuos es un problema de optimización combinatoria, por las posibles combinaciones que pueden existir entre los residuos, que posibiliten analizar esas propiedades, En ese sentido, técnicas inteligentes como los AG permiten explorar el espacio de posibles alternativas, de tal manera de obtener las combinaciones de residuos que permitan distinguir dichas propiedades, si existen.

Con la ayuda otro AG, se realiza un modelo que determine la localización de sensores en un sistema que no permita la detección y/o aislamiento de fallas. Esto se debe a que no se cuenta con suficientes variables observadas (medidas) en el sistema, por lo cual, este modelo inteligente basado en AG propone la localización de los sensores en aquellas variables no observadas, que incrementen la redundancia del proceso, y así, poder evaluar la propiedad de diagnosticabilidad en el proceso.

En ese sentido, en este trabajo se propone un Modelo Inteligente para el análisis de diagnosticabilidad en los procesos de extracción de petróleo por inyección de gas, como primer paso para el análisis en sistemas de producción de petróleo. De esta manera, analizar la propiedad de diagnosticabilidad, en términos de detectabilidad y aislabilidad de un conjunto de fallas consideradas, y de no ser así, determina qué variables del sistema son necesarias observar para determinar la propiedad antes mencionada.

Por ello, este trabajo presenta temas vinculados al diagnóstico, a modelos de diagnosticabilidad, análisis de diagnóstico basados en modelos estructurales según métodos de la comunidad FDI, así como también, temas vinculados a herramientas computacionales evolutiva como la técnica usada en este trabajo, y su uso en problemas de optimización combinatoria, en particular, para determinar el óptimo emparejamiento de variables en grafos bipartitos.

1.4. OBJETIVOS

OBJETIVO GENERAL

Desarrollar un Modelo Inteligente para el análisis de diagnosticabilidad en procesos de producción.

OBJETIVO ESPECÍFICOS

1. Estudiar los diferentes modelos de diagnosticabilidad en el ámbito de procesos continuos.

2. Diseñar un modelo de diagnosticabilidad orientado a procesos de producción. Particularmente, el caso de estudio se enfocará en el problema de diagnosticabilidad en pozos de petróleo con levantamiento artificial por inyección de gas.
3. Estudiar el uso de técnicas del área de Inteligencia Artificial en tareas de diagnosticabilidad de procesos de producción.
4. Extender los modelos de diagnosticabilidad orientados al proceso de producción estudiado en este trabajo, con las técnicas de inteligencia artificial adecuadas para el caso de estudio.
5. Experimentar con el modelo desarrollado en la investigación en procesos de extracción de petróleo basada en levantamiento artificial por gas.

1.5. ALCANCE

Este proyecto diseña e implementa un macro algoritmo que contiene los AGs que permiten realizar satisfactoriamente las tres tareas, para hacer un análisis de diagnosticabilidad en el caso de estudio:

1. Se utilizan inicialmente métodos FDI para obtener las ecuaciones de redundancia analítica, así como un AG para evaluar dichas ecuaciones y chequear sus capacidades de detectabilidad en el proceso.
2. Se utiliza un segundo AG para evaluar las propiedades de detectabilidad y aislabilidad de fallos, y en particular, para obtener la matriz de firma de fallas del sistema con la mínima cantidad de residuos posibles.
3. Finalmente, se usa un AG capaz de obtener una población de posibles configuraciones de localizaciones de sensores, donde las propiedades de detectabilidad y de aislabilidad son analizadas.

Se desarrolló un prototipo para realizar las pruebas de concepto respectivas, el cual, cumple con los requerimientos de eficiencia necesarios para que el sistema pueda ejecutarse en una computadora personal moderna.

Por otra parte, para el primer modelo se usó el algoritmo propuesto en [21], y se modificó para adaptarlo al caso de estudio, desarrollándose un prototipo personalizado del mismo. Sobre ese prototipo se hicieron las pruebas de conceptos, y ambos prototipos son usados para realizar las comparaciones entre los dos enfoques.

1.6. ACTIVIDADES DOCTORALES DESARROLLADAS DURANTE LA TESIS

En el marco de la tesis se realizaron varias actividades doctorales, en particular se realizaron cuatro pasantías de investigación, de alrededor tres meses cada una, en el grupo DISCO (DIagnostic, Supervision et CONduite) del LAAS (Laboratoire d'analyse et d'architecture des systèmes), en Toulouse Francia. Además, se realizaron otras dos actividades.

a) DICTADO DE SEMINARIOS

- Diagnosticabilidad en los Procesos de Producción, en Mayo de 2011.
- Desarrollo de un Modelo Inteligente Orientado a Condiciones de Diagnosticabilidad en Procesos de Producción de petróleo, en Enero de 2013.
- Desarrollo de un Modelo Inteligente Orientado a Condiciones de Diagnosticabilidad en Procesos de Producción, en Octubre de 2014.
- Desarrollo de un Modelo Inteligente Orientado a Condiciones de Diagnosticabilidad en Procesos de Producción, en Enero de 2015.

b) PUBLICACIONES

- R. Leal, J. Aguilar, E. Camargo, A. Ríos, “Modelo de Diagnosticabilidad para Procesos de Producción Petrolero”. *Proceeding of the 5to Congreso Iberoamericano de Estudiantes de Ingeniería Eléctrica (V CIBELEC 2012)*, pp. C17-C23, 2012.
- R. Leal, J. Aguilar, L. Trave-Massuyes, A. Ríos, E. Camargo. "A Genetic Algorithm Approach for Diagnosability Analysis", *International Journal of Engineering Development and Research*; vol.2(4), pp. 3786-3799, 2014.
- R. Leal, J. Aguilar, E. Camargo, A. Ríos, L. Travé, “Analysis of diagnosability for gas lift Wells”, *Ingeniería y Ciencias Aplicadas: Modelos Matemáticos y Computacionales (Ed. E. Dávila, J. Del Río, M. Cerrolaza, R. Chacón)*, Sociedad Venezolana de Métodos Numéricos en Ingeniería; pp. EC91-EC97, 2014.
- R. Leal, J. Aguilar, L. Travé-Massuyès, A. Ríos, E. Camargo. "An approach for diagnosability analysis and sensor placement for continuous processes based on evolutionary algorithms and analytical redundancy”, *Applied Mathematical Sciences*: vol. 9(43), pp. 2125-2146, 2015.
- R. Leal, E. Camargo, J. Aguilar, A. Ríos, L. Travé-Massuyès, “Análisis de Diagnosticabilidad y Localización de Sensores en un Pozo de Extracción de Petróleo por Inyección de Gas”, *Revista Politécnica – EPN Journal*: vol. 36(1), pp. 1-11, 2015.

1.7. ORGANIZACIÓN DE LA INVESTIGACIÓN

El Capítulo II comprende los aspectos teóricos necesarios para la comprensión del trabajo desarrollado en la tesis. Los temas principales que aborda ese capítulo son: Diagnóstico, Diagnosticabilidad, la Técnica Inteligente utilizada (AG), y se describe el caso de estudio (Extracción de petróleo basada en Levantamiento Artificial por inyección de Gas). Este capítulo termina analizando la interrelación de cada uno de los temas.

En el Capítulo III se profundiza la explicación de la técnica de diagnóstico basado en modelos utilizada en este trabajo, la cual es el Análisis de Redundancia Analítica mediante

el Análisis Estructural. Además, se presentan varios experimentos usando esta técnica, tanto en un ejemplo de un sistema no lineal como en el caso de estudio.

En el Capítulo IV se presentan los aportes fundamentales de esta investigación, en donde se encuentra el diseño del modelo de diagnosticabilidad basado en AG, que realiza el análisis de diagnosticabilidad para determinar las propiedades de detectabilidad y aislabilidad de fallas. Posteriormente, un análisis de localización de sensores en el caso de que no se puedan distinguir alguna de las propiedades anteriores, incrementando la redundancia del sistema. De igual manera que en el Capítulo IV, se realizan experimentos en los mismos ejemplos del Capítulo III, para verificar la funcionabilidad de la propuesta. Los casos de prueba permiten determinar la eficacia y eficiencia del modelo propuesto basado en el AG. El capítulo termina con una comparación entre las técnicas de diagnosticabilidad propuestas en trabajos previos, con la técnica propuesta en este trabajo. Igualmente, se comparan otros enfoques de localización de sensores presentados en trabajos anteriores, con la propuesta hecha en este trabajo.

Finalmente, el Capítulo VI contiene las conclusiones generales de la tesis y los trabajos futuros que podrían ser realizados, para continuar la investigación en este campo del conocimiento.

CAPÍTULO II MARCO TEORICO

La presente investigación considera tres áreas principales de estudios, estas son: el diagnóstico de fallas de procesos industriales, estudiando en particular, la propiedad de diagnosticabilidad de los procesos; las técnicas de computación inteligente; y por último, el caso de estudio, referido al método de extracción de petróleo mediante el levantamiento artificial por inyección de gas. En tal sentido, a continuación se da una visión general de los conceptos más relevantes de cada una de estas disciplinas.

2.1. DIAGNÓSTICO

En principio, es necesario hacer un breve inciso sobre las características de la supervisión y control en los procesos de producción, debido a que estos sistemas pueden ser afectados por fallas que conllevan a un mal funcionamiento de los mismos [38]. En general, los sistemas de supervisión y control constituyen una herramienta importante para la industria, ya que permiten automatizar los procesos, haciendo que los mismos sean más efectivos en el uso de la infraestructura y en el manejo de los recursos. La automatización de las tareas brinda, entre otras cosas, la posibilidad de realizar el diagnóstico de fallas.

Básicamente, una falla significa cualquier cambio en el comportamiento de cualquier componente de un sistema, por lo que ya no puede satisfacer la función para la que fue diseñado [39]. Además, por detección se entenderá la capacidad de determinar si una falla ha ocurrido. El diagnóstico de fallas consiste en detectar la presencia de las mismas y el comportamiento anormal en el proceso, e identificar y localizar el componente o la causa que originó la anomalía. Normalmente, los objetivos del diagnóstico de fallas son [12, 37, 38]:

- Detección de las fallas.
- Aislamiento de las fallas.

- Identificación y estimación de las fallas.

En virtud de dar respuesta al problema de investigación y a sustentar teóricamente los indicadores bajo estudio, se procede a definir algunos conceptos claves en automatización vinculados con la presente investigación.

Definición 1: Supervisión. Son las funciones de observaciones que indican los estados y eventos del proceso, con el fin de identificar los estados indeseables o no permitidos de dichos procesos, para tomar acciones apropiadas que permitan mantener el funcionamiento y evitar daños o accidentes [40].

En general, las variables medibles son revisadas con respecto a sus tolerancias, y en caso de ser necesario se generan alarmas para el operador. Así, en supervisión se pueden distinguir las siguientes funciones [38, 39]:

- a) *Supervisión con control:* en el caso de procesos importantes, la función de supervisión automáticamente inicia una acción de control apropiada para contrarrestar los efectos del fallo. Lo anterior, con el fin de evitar en la medida de lo posible los daños.
- b) *Supervisión con diagnóstico de fallas:* basándose en las variables medidas, se generan los síntomas, para posteriormente realizar el diagnóstico y tomar las decisiones para corregir los fallos, o contrarrestar sus efectos nocivos.

Las ventajas de los métodos de supervisión clásicos son su simplicidad [37]. Sin embargo, ante un cambio repentino de una característica, o ante una falla que imperceptiblemente se incrementa a través de un largo período de tiempo, estos métodos pueden fallar. Además, en ocasiones estos métodos no cuentan con herramientas suficientes para profundizar en el análisis de un fallo.

Por consiguiente, son necesarios métodos avanzados de supervisión y diagnóstico de fallas, que se basen en las variables medidas y características calculadas (residuos, medias, históricos de falla, frecuencias de aparición, entre otros), adecuadas para la generación de

síntomas, de manera que cuando ocurra un cambio en ellas pueda ser detectado, además, se realice un diagnóstico apropiado que genere acciones correctivas adecuadas. Los requerimientos que los métodos avanzados de supervisión y diagnóstico deben cumplir son [39]:

- Detección temprana de fallas pequeñas, con abrupto o incipiente comportamiento temporal.
- Diagnóstico de fallas en el elemento de control, en los componentes del proceso, o en los sensores.

La meta del diagnóstico es la detección temprana, para que de esa manera, tener el tiempo suficiente para contrarrestar las consecuencias que pudiera traer una falla, a través de operaciones de reconfiguración, mantenimiento o reparación. La detección temprana puede ser lograda adquiriendo más información sobre el proceso, usando las relaciones entre las variables medidas en los modelos matemáticos, entre otras cosas.

Definición 2: Diagnóstico. Por diagnóstico se asume en la presente investigación, la tarea de determinar cuáles son las causas de un comportamiento incorrecto en un sistema. El problema de diagnóstico puede ser formulado según [38] como: dado el modelo de un sistema y un conjunto de variables medidas desde el sistema, detectar una posible falla y determinar sus causas.

Definición 3: Detectabilidad. Es la capacidad para detectar todas las fallas consideradas en un sistema [13]. El diagnóstico debe ser capaz de decidir si existe una falla o no, así como determinar el instante de la aparición, a partir de observaciones del proceso. Para ello, puede ser necesario el comparar el comportamiento real con el comportamiento nominal.

Definición 4: Aislabilidad o separabilidad. Es la capacidad de identificar una falla producida en un sistema a partir de todas las fallas que son detectables [13]. La aislabilidad de la falla se basa en la diferenciación entre el comportamiento anormal del proceso,

derivado por la falla con respecto al comportamiento anormal de otras fallas, con el fin de determinar esa falla y su diferencia con el resto de las otras fallas.

Por otra parte, existen una gran cantidad de métodos desarrollados en el mundo académico e industrial para el diagnóstico de fallas, los cuales se agrupan o clasifican de acuerdo a los diferentes enfoques encontrados en la literatura. La selección de un método para realizar el diagnóstico de fallas en un proceso, depende del conocimiento y de la cantidad de información del sistema, de la dinámica, complejidad, linealidad del proceso y de las relaciones entre las observaciones (mediciones) y las fallas, entre otros.

En términos generales, se pueden distinguir dos grandes grupos de métodos de detección de fallas; aquellos que se basan en el modelo del proceso y los que no hacen uso del modelo de él.

Para el primer grupo se utilizan métodos analíticos, es necesario tener un conocimiento a priori del proceso, y a su vez, se divide en métodos que utilizan un modelo cuantitativo o un modelo cualitativo del proceso. Los modelos están basados fundamentalmente en el entendimiento, que viene expresado en términos de funciones matemáticas que relacionan las entradas y las salidas del sistema. Se realiza una descripción precisa del mismo, y su dinámica suele ser representada por ecuaciones dinámicas. En los modelos cualitativos se realizan inferencias sobre el comportamiento de ciertos elementos del proceso, para expresar, con funciones cualitativas las relaciones.

En el segundo grupo, en contraste con los métodos basados en modelos, se encuentran los que contemplan el conocimiento histórico del proceso, donde es necesaria la disponibilidad de grandes volúmenes de información. Estos métodos generan un modelo desde los datos históricos del proceso, estableciendo relaciones cuantitativas o cualitativas entre las variables presentes en el sistema.

En líneas generales, todos los métodos requieren datos para estimar algunos parámetros, y todos extraen del proceso información relevante para aplicar la técnica en el

método de diagnóstico a realizar. En la literatura, encontramos que los métodos de diagnóstico de fallos pueden clasificarse de diferentes maneras. En este trabajo se utiliza la clasificación presentada por [41] (ver Figura 2.1).

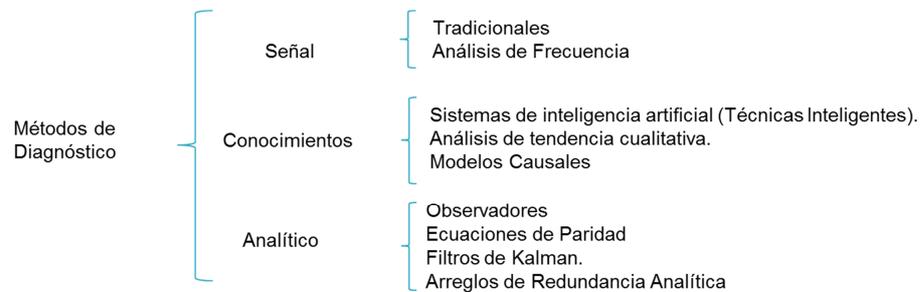


Figura 2.1 -Métodos de diagnóstico de fallas.

Debido a la amplia variedad de métodos, no es posible discutir en detalle todos ellos, por lo que se realizará énfasis solo en los métodos usados en este trabajo.

En la presente investigación, el método utilizado es el *método analítico*. Entre las técnicas de diagnóstico con este método se encuentra la redundancia física; en los cuales se hace uso de las réplicas físicas de los dispositivos y sistemas bajo estudio, pero generalmente son demasiados costosos. Por otra parte, existen los métodos de diagnóstico basado en modelos; a partir de los cuales se pueden producir valores estimados, reducir o eliminar las variables desconocidas de los procesos para la generación de los residuos. El principal inconveniente es construir un modelo, o disponer de modelos precisos [41].

Desde el punto de vista de la generación de residuos, se puede utilizar las técnicas basadas en la comunidad FDI usado en [12]. El principio básico consiste en comparar el comportamiento actual del sistema con un modelo analítico de referencia, el cual representa el comportamiento normal. Al momento que ocurre una falla en el sistema la comparación de ambos produce un resultado diferente de cero, este resultado se conoce como *residuo*. Los residuos tienen la propiedad de que, en el caso de que todos los componentes del sistema estén en el estado de funcionamiento normal sus valores son nulos, en el caso contrario, sus valores no son nulos (cuando alguno de los componentes caracterizados por

los residuos presenta una falla). Las técnicas de generación de residuos forman parte del área de MBD.

En MBD, los aspectos fundamentales son la definición de un modelo del proceso, la comparación de los elementos observables con el funcionamiento del modelo, y el análisis del comportamiento de estos elementos [42].

En la *redundancia directa* se utilizan las relaciones algebraicas entre las mediciones de los diferentes sensores, parámetros internos del proceso que sean medibles, sin importar su naturaleza, considerando que se producen de un mismo estado dinámico, y por lo tanto, deben estar funcionalmente relacionados a través de su modelo, y las relaciones matemáticas que computan dicho valor. En la *redundancia temporal*, las entradas y las salidas conocidas (medidas) del sistema se relacionan con ecuaciones diferenciales.

En general, el análisis de residuos consta de dos pasos. El primer paso, genera los residuos, utilizando el modelo, las entradas y las salidas del sistema; se realiza mediante un algoritmo determinado, de acuerdo al método escogido para generar los residuos. En el segundo paso, los residuos se examinan para determinar si han ocurrido fallas o no. Además, los mismos se colocan en un vector de residuos, que tiene la propiedad de aislamiento si todos los fallos pueden distinguirse unos de otros.

Definición 5: Residuo. De acuerdo a un método de análisis de diagnóstico seleccionado, la diferencia entre la comparación de un sistema con el modelo del mismo, a través de las entradas, las salidas y todas aquellas variables conocidas, se produce un residuo. Normalmente su valor es casi nulo, y se desvían de cero de forma característica cuando ocurre una falla particular.

Una forma de generación de residuos es por medio de las relaciones de redundancia analítica [12, 15, 16], cuyo objetivo principal es diseñar una función con alta sensibilidad a las fallas. Para ello se utiliza un subconjunto de las ecuaciones que caracterizan el sistema, las cuales estarán compuestas únicamente por variables conocidas, las cuales, son medidas o

calculadas en un paso anterior. Dicho subconjunto de ecuaciones son usadas en el momento que existe una perturbación, de manera que, la evaluación final de los residuos de las que ellas forman parte. La generación de un residuo estará compuesta por una secuencia finita de cálculos, que termina con una ecuación analíticamente redundante (ARR), donde en cada paso sólo se requiere de variables conocidas. Métodos similares han sido utilizados en [5, 10, 12].

En el caso de detección de fallas, la señal del residuo es idealmente cero en el caso de no existir un fallo, y diferente de cero en el caso contrario. Un residuo puede ser caracterizado mediante un ARR, el cual toma las variables observadas o conocidas del sistema como entrada, y produce un residuo como salida.

Dado que el caso de estudio es un proceso de producción continuo, además de que se cuenta con un modelo analítico del proceso (presentado en [30]), la forma para la generación de residuos usada en este trabajo está basada en el enfoque de ARR. Se utilizan modelos matemáticos analíticos que caracterizan el sistema, para reproducir el comportamiento de los componentes o del sistema bajo evaluación. En particular, el enfoque ARR utilizado en esta investigación y es detallado en el capítulo 3 de este trabajo, y la técnica utilizada para este enfoque es el análisis estructural.

El modelo estructural del proceso solo requiere tener el conocimiento de las variables que aparecen en cada ecuación, sin importar la forma detallada de la expresión matemática del proceso. La primera etapa consiste en realizar un análisis matemático previo del sistema usando análisis estructural [13]. A partir de allí, se realiza la tarea de diagnóstico a través de la comparación de las señales del modelo con las señales del sistema real. Posteriormente, se hace un análisis de las propiedades de detección y aislamiento de fallas. Finalmente, se toman decisiones según los resultados del paso anterior, en cuanto al control o cambios a realizar en el proceso en sí (por ejemplo, incorporar nuevos sensores en el sistema real).

Como hemos dicho, un modelado completo del problema de diagnóstico de fallas se puede abordar desde múltiples puntos de vista, el de la comunidad de control automático

(FDI), que utiliza técnicas analíticas para elaborar un modelo explícito de los procesos, o el de la comunidad científica de diagnóstico (DX) que basa sus trabajos principalmente en la inteligencia artificial. Este trabajo mezcla las ideas de ambas comunidades.

2.2. DIAGNOSTICABILIDAD

El concepto fundamental de la presente investigación es el de diagnosticabilidad.

Definición 6: Diagnosticabilidad. Un sistema tiene la propiedad de diagnosticabilidad, si a través de un método de diagnóstico se pueden detectar y aislar todas las fallas consideradas.

Las fallas que se aíslan en un proceso se refieren a menudo como “fallas monitoreadas”, mientras que las fallas que no se aíslan se llaman “fallas no supervisadas”. Por otro lado, la disociación de las fallas se puede hacer, por ejemplo, a partir de pruebas en los residuos, entendiendo que los residuos deben ser sensibles, o responder a diferentes subgrupos de fallas [1]. Por lo tanto, la disociación de las fallas es un problema fundamental en la generación de residuos para el aislamiento de fallos, para obtener la diagnosticabilidad.

La diagnosticabilidad es un factor muy importante en el diseño de un proceso, debido a que es una herramienta que ayuda al diseñador a determinar la localización de los sensores del sistema y obtener el máximo rendimiento de los mismos, de manera de reducir costos e incrementar las posibilidades de detección y comprensión de las perturbaciones.

A continuación se presentan algunos conceptos acerca de la diagnosticabilidad, y los métodos para realizar el análisis de las propiedades de detectabilidad y aislabilidad, los cuales son de interés para la presente investigación.

2.2.1. DIAGNOSTICABILIDAD BASADOS EN MODELOS

En los años 70 se inició el diagnóstico basado en modelos (MBD), como una aplicación de la teoría de observadores utilizados en el área de control automático. Dicho diagnóstico de fallas basado en modelos consiste en la detección de fallas en procesos, incluyendo sensores y actuadores, mediante la evaluación de la consistencia entre un modelo matemático y las mediciones en el proceso [42].

Dado que en MBD es fundamental un modelo matemático, consideremos el siguiente modelo M de un sistema, y es el que se utilizara a lo largo de esta sección;

$$\dot{x} = b(x, u, f) \quad (2.1)$$

$$y = h(x, u, f) \quad (2.2)$$

El vector de variables de estado desconocidas es determinado por $x \in \mathbb{R}^n$; y el vector de variables conocidas, calculadas o medidas, están representadas por $y \in \mathbb{R}^m$ y $u \in \mathbb{R}^c$, donde f representa las fallas $f \in \mathbb{R}^l$, como por ejemplo, la falla de un actuador, la falla de un sensor, o la una falla en el proceso. La relación entre las ecuaciones de un modelo y las variables está determinada por b y h , las cuales generalmente son funciones polinomiales no lineales.

La idea principal del análisis con MBD es remplazar la redundancia física por la redundancia analítica, al desarrollar modelos con la capacidad de generar residuos. La suposición general es que los residuos cambian lo suficiente como para ser detectados. Este enfoque requiere que el proceso se pueda describir generalmente por un modelo analítico. El principio comúnmente usado en la detección de falla en MBD se ilustra en la Figura 2.2. Este esquema involucra tres etapas, la generación de residuos, la evaluación de residuos y la decisión de diagnóstico a partir de los valores de los residuos.

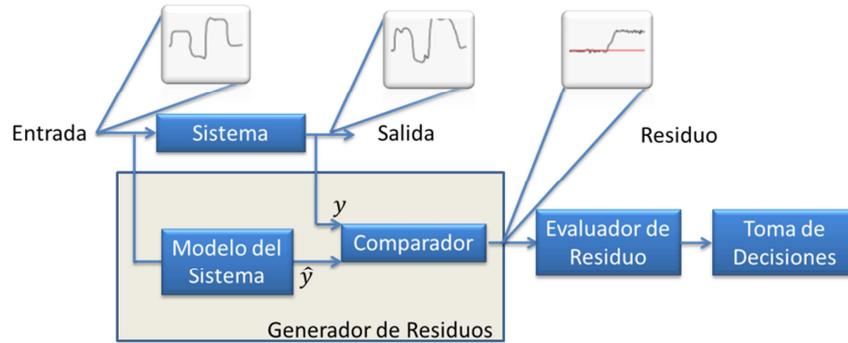


Figura 2.2- Sistema generador de residuos utilizando MBD

Descrito lo anterior, se puede concluir que en presencia de una falla se puede utilizar las señales del residuo para detectar la misma. En este trabajo, los residuos son considerados como señales de salida de un modelo, a través de la eliminación de las variables desconocidas del sistema, los que nos lleva a la siguiente definición.

Definición 7: Generador de residuos. Un generador de residuos de un sistema, para un conjunto de fallas f , toma como entradas el conjunto de variables medidas o calculadas (y,u) , las procesa mediante un método de diagnóstico seleccionado, y produce un conjunto de residuos $R = \{R_1, \dots, R_g\}$ como salida, basado en una función q que caracteriza la relación entre las variables.

Para generar residuos mediante métodos analíticos, se reducen o eliminan las variables desconocidas de un sistema. Entre las metodologías que se pueden utilizar, existen los que estiman las variables desconocidas, para generar residuos con características como (2.3). Otra manera para obtener residuos, es eliminando las variables desconocidas mediante la paridad del sistema, obteniendo residuos con características como en (2.4). También se pueden obtener residuos, mediante las derivadas de los estados conocidos hasta un orden necesario, que permita eliminar los estados desconocidos, con características como (2.5).

$$R = q(\hat{x}, u, y, \hat{y}) \quad (2.3)$$

$$R = q(u, y) \quad (2.4)$$

$$R = q(u, \dot{u}, \ddot{u}, \dots, y, \dot{y}, \ddot{y}, \dots) \quad (2.5)$$

La evaluación de los residuos permite examinar el efecto de cada residuo con respecto a las fallas, con el fin de determinar si las fallas se pueden detectar o no en el sistema, e incluso caracterizar el comportamiento del conjunto de residuos frente a un conjunto de fallas, para discernir la aislabilidad de las mismas (ver Figura 2.3).

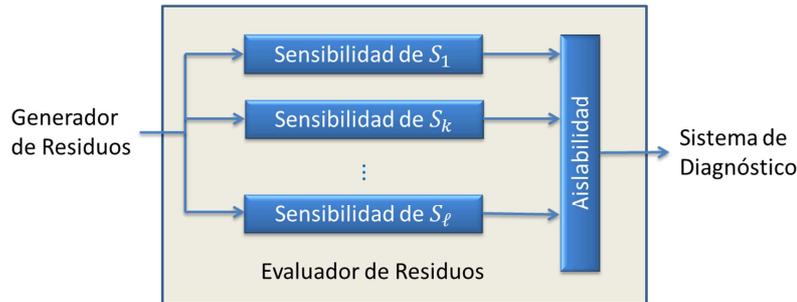


Figura 2.3 - Sistema evaluador de residuos, para ℓ fallas.

Así, el problema de detección de fallas se puede abordar por medio de la evaluación de residuos, en el sentido de que en el comportamiento de un conjunto de residuos frente a un conjunto de fallas, al menos un residuo R_k , donde $k = \{1, \dots, g\}$ y g es el número de residuos, debe ser sensible a cada falla $f_i \forall i = \{1, \dots, \ell\}$. Los residuos se hacen sensibles a un conjunto determinado de fallas e insensibles a otros ciertos grupos. Esa propiedad de sensibilidad o insensibilidad permite determinar el conjunto S_i para cada falla f_i , el cual es un conjunto de 0s y/o 1s en g , tal que

$$S_{ik} = \begin{cases} 1; & \text{si } R_k \in R \text{ es sensible a } f_i, \forall k = \{1, \dots, g\} \\ 0; & \text{de lo contrario} \end{cases} \quad (2.6)$$

La expresión en (2.6) denota la sensibilidad S_i del conjunto de residuos R a la falla f_i . Una falla f_i puede ser sensible a uno o más residuos que pertenezcan al conjunto R .

Considere un sistema de diagnóstico que contenga un conjunto $S = \{S_1, S_2, \dots, S_\ell\}$. Según la definición de sensibilidad a f_i definida en (2.6), en S_i al menos uno de sus elementos es diferente a 0 si existe algún residuo que pertenece al conjunto R sensible a f_i , lo que garantiza la detección de f_i .

El problema de la separación/aislabilidad de las fallas es más complicado que el problema de detección. En particular, (2.7) representa el análisis de la sensibilidad S de un sistema para sus ℓ fallas, tal que, cada S_i representa el comportamiento de sensibilidad de cada falla f_i . En este caso, se debe garantizar que cada S_i sea linealmente independiente del resto de fallas, para garantizar la aislabilidad de las fallas.

$$S = \bigcap_{i=1}^{\ell} S_i \quad (2.7)$$

Por ejemplo, si se realiza una análisis del comportamiento del conjunto de sensibilidad durante la presencia de f_i y f_j , para $i \neq j$, el análisis de sensibilidad debe permitir discernir entre f_i y f_j , es decir, que $S_i \cap S_j = \emptyset$, $\forall (S_i, S_j) \in S$.

Para poder realizar el análisis de diagnosticabilidad, es necesario reducir las variables desconocidas. Partiendo de un modelo, se pueden estimar, calcular o eliminar estas variables desconocidas, y de esta manera analizar la redundancia del sistema. Existe una variedad de métodos que se reportan en la literatura para lograr este objetivo [17, 41, 42, 50, 51]. A continuación se discuten brevemente algunos de estos métodos. El enfoque de ARR se describe de manera detallado en el Capítulo 3, ya que es el utilizado en la propuesta.

- **Observadores**

Este método se basa en la observabilidad del sistema. Son elementos que permiten estimar las variables desconocidas de un sistema, a través de las mediciones disponibles del proceso [17]. Las aplicaciones de los observadores son muy variadas y existen una gran cantidad de técnicas para lograr su fin [17, 50, 51], y en el caso de análisis de diagnóstico de fallas, se basan en el error de estimación del observador e , para eliminar las variables desconocidas a partir de sus estimaciones. Por esta definición, se considera un error de estimación para cada variable desconocida x como $e_x = x - \hat{x}$.

Por ejemplo, supongamos el sistema descrito en (2.1) y (2.2), cuya estimación de las variables desconocidas y de la salida (\hat{x}, \hat{y}) son mostradas en (2.8) y (2.9).

$$\dot{\hat{x}} = d(\hat{x}, u, y) \quad (2.8)$$

$$\hat{y} = h(\hat{x}, u) \quad (2.9)$$

Cuando cada e converja asintóticamente a cero, se eliminan las variables desconocidas, lo que permite comparar la salida estimada con la verdadera. Así que, para el sistema del ejemplo se puede obtener un residuo (2.10).

$$R = (y - \hat{y}) \quad (2.10)$$

El problema en el contexto de un observador, es la generación de un conjunto de residuos que permitan detectar y diagnosticar todas las fallas.

La idea básica es que, en un caso sin fallas, los observadores generen una buena aproximación de la señal de interés y los residuos sean pequeños o ceros. Si ocurre una falla, todos los observadores que se diseñen para ser insensibles a esta falla continúan dando residuos casi nulos. Por otro lado, los observadores que son sensibles a la falla se deben desviar significativamente del proceso y generar residuos de mayor magnitud.

Ahora bien, el problema en el diseño de los observadores, consiste en definirlos, tales que sus errores de estimación exhiban características unidireccionales asociadas con algunas de las fallas conocidas, para garantizar la detectabilidad.

En general, el uso de la técnica de observadores se dificulta debido a la alta complejidad para definirlos, aún más en sistemas no lineales, o en sistemas con grandes conjuntos de variables desconocidas, por lo que su uso en este trabajo no se consideró.

- **Espacios de paridad**

En las relaciones de paridad el sistema de ecuaciones se reorganiza, y por lo general se transforman, variantes del modelo de entrada y salida de un sistema. El método se basa en comprobar la paridad (coherencia) de las variantes del modelo del sistema, usando para ello las entradas, salidas y otras variables del proceso (sus mediciones).

Consideremos el sistema descrito en (2.11) y (2.12);

$$\dot{x} = Ax + Bu \quad (2.11)$$

$$y = Cx \quad (2.12)$$

Como se muestra en [50], en el análisis de ecuaciones de paridad para sistemas continuos, la estructura del modelo se reorganiza, insertando ecuaciones de estados en el sistema, de lo cual resultan derivadas de variables con un orden suficiente que permita eliminar los estados no medibles x (ver (2.13)), obteniendo ecuaciones de paridad que solo contengan la relación de entradas y salidas (2.14), tal que sea una relación de paridad únicamente al desaparecer los estados desconocidos [41, 50].

$$\begin{bmatrix} y \\ \dot{y} \\ \ddot{y} \\ \vdots \end{bmatrix} = \begin{bmatrix} C \\ CA \\ CA^2 \\ \vdots \end{bmatrix} x + \begin{bmatrix} 0 & 0 & 0 & \dots \\ CB & 0 & 0 & \dots \\ CAB & CB & 0 & \dots \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix} \begin{bmatrix} u \\ \dot{u} \\ \ddot{u} \\ \vdots \end{bmatrix} \quad (2.13)$$

$$y = Tx + Qu \quad (2.14)$$

Bajo esta suposición, para eliminar los estados desconocidos x , se puede construir a partir de la elección adecuada de una transformada W (2.15), estructurando un residuo como en (2.16);

$$WT = 0 \quad (2.15)$$

$$R = W(y - Qu) \quad (2.16)$$

Por lo general, este método no funciona en sistemas no lineales, el vector de paridad debe ser de alto orden, lo que hace su cálculo complejo, existiendo además la posibilidad que se pierda la detección de las fallas [41].

- **Filtros Kalman**

Los Filtros de Kalman son otro método analítico, que consiste en monitorear los cambios del proceso mediante los datos que el mismo arroja. El filtro de Kalman utiliza un algoritmo recursivo, lo que facilita su implementación en sistemas de tiempo real, y es diseñado en base al modelo que representa las condiciones normales de operación. El filtro produce una secuencia de estimaciones independientes y de media nula (predicciones de errores), con el objetivo de construir estimadores cuya estimación del error es mínima.

Usando el sistema descrito en (2.17) y (2.18), el caso del filtro Kalman en la estimación de estados x es como en los observadores. El filtro Kalman se considera como un estimador óptimo, ya que, toma en cuenta ruidos (w, v) , la covarianza Σ , y las matrices de dimensiones adecuadas A , B y C son;

$$\dot{x} = Ax + Bu + w \quad (2.17)$$

$$y = Cx + v \quad (2.18)$$

Con la esperanza $E\{w\} = 0$ y $E\{v\} = 0$, y las matrices de las covarianzas $Q = E\{(w^T w)\}$ y $H = E\{(v^T v)\}$, tales que se cumple la siguiente relación:

$$E\left\{\begin{pmatrix} w \\ v \end{pmatrix} \begin{pmatrix} w^T & v^T \end{pmatrix}\right\} = \begin{pmatrix} Q & D \\ D^T & H \end{pmatrix} \quad (2.19)$$

D es una matriz calculada con dimensiones adecuadas, que permite cumplir que Q y H sean independientes. En la estimación de x basada en las observaciones de (y, u) , se busca minimizar la función de costo $J = E\{(e^T e)\}$, donde E es la esperanza matemática, $(e^T e)$ es el error cuadrático, y e el error de estimación (definida como $e = (x - \hat{x})$) [51].

K es la ganancia del filtro de Kalman, que es seleccionada para conseguir las mejores estimaciones posibles de los estados descritos en (2.20), en el sentido de la varianza mínima que está dada por (2.21):

$$\hat{\dot{x}} = A\hat{x} + Bu + K(y - C\hat{x}) \quad (2.20)$$

$$K = (A\Sigma C^T + D)(C\Sigma C^T + H)^{-1} \quad (2.21)$$

Donde $\Sigma \in^{n \times n}$ es la matriz de covarianza de los n estados desconocidos del sistema según [51].

Según lo descrito antes el filtro Kalman permite estimar las variables desconocidos. Entonces, un residuo se puede obtener por la comparación de la salida real con la estimada, donde $R = (y - \hat{y})$.

Diversos enfoques de diagnóstico han sido desarrollados utilizando filtros Kalman para detectar y aislar fallas, desarrollándose bancos de filtros para generar residuos que permiten identificar los comportamientos en el sistema, con capacidad de detectar y aislar las fallas consideradas [17, 51].

En el caso de grandes y complejos sistemas, los enfoques basados en modelos analíticos nombrados anteriormente pueden garantizar la detección de fallas. Sin embargo, garantizar la aislabilidad se dificulta, en particular, en sistemas no lineales o con gran cantidad de variables desconocidas. En el Capítulo 3 se realiza una descripción del enfoque de ARR, que consiste en la eliminación de las variables desconocidas, a diferencia de los enfoques anteriores, que tratan de estimarlos [15, 16].

En el Capítulo 4 se desarrolla una propuesta para optimizar el análisis de diagnóstico con el método tradicional de ARR, cuando la cantidad de residuos es compleja, lo cual dificulta definir las relaciones de redundancia. Para ello, se usa un enfoque híbrido basado en el método ARR y en técnicas inteligentes, para generar relaciones de redundancias analíticas con información suficiente para obtener residuos. Además, el enfoque híbrido selecciona la cantidad de residuos exactos para un mejor análisis de detectabilidad y aislabilidad.

2.3. TÉCNICAS INTELIGENTES.

En general, las técnicas inteligentes son herramientas computacionales de la rama de la inteligencia artificial, centradas en el estudio de mecanismos adaptativos, normalmente biológicos, para inspirarse en ellos y proponer sistemas computacionales con comportamiento inteligente. En [44] se definen las técnicas inteligentes como una metodología de cálculo que tiene habilidades para adaptarse a nuevas situaciones, la cual posee atributos de razonamiento, tales como: generalización descubrimiento, asociación, y abstracción; además, sus respuestas son predicciones o toma de decisiones.

Los AG forman parte de las técnicas inteligentes, en específico de la sub-área computación evolutiva, siendo los más utilizados para resolver problemas de optimización combinatoria, lo cual es el caso bajo estudio, de allí que en la presente investigación se centralice en esta herramienta en la siguiente sección.

Existen otras técnicas bio-inspiradas en el ámbito de la computación inteligente, como lo son: los sistemas artificiales de hormigas, los sistemas inmunológicos artificiales, las redes neuronales artificiales, entre otros; las cuales también han tenido cierto impacto en estos tipos de problemas.

2.3.1. ALGORITMO GENÉTICO

Los AG han sido empleados en dos áreas principalmente [43]: optimización y aprendizaje de máquina. En el caso de la optimización, han sido usados en campos muy diversos tales como optimización de funciones, problemas de optimización combinatorias (como el agente viajero), planificación de procesos, entre otros [44]. En aprendizaje de máquina, los AG han sido usados para aprender reglas de cadenas sintácticamente simples: “SI” (condición), “ENTONCES” (Conclusión).

Concisamente, un AG es una técnica de programación que imita la evolución biológica como estrategia para resolver problemas [43, 44, 45]. Dado un problema específico a resolver, la entrada del AG es un conjunto de soluciones potenciales a ese

problema, codificadas de alguna manera, y una métrica llamada función de aptitud, que permite evaluar cuantitativamente a cada candidata. Estas candidatas pueden ser soluciones que ya se sabe que funcionan, con el objetivo de que el AG las mejore, pero se suelen generar aleatoriamente.

Un AG evalúa cada candidata de acuerdo con la función de aptitud. En un acervo de candidatas generadas aleatoriamente, algunas no funcionarán en absoluto, y serán eliminadas. Sin embargo, otras pueden ser prometedoras soluciones del problema. Estas candidatas prometedoras se conservan y se les permite reproducirse. Se realizan múltiples copias de ellas, pero las copias no son perfectas; se introducen cambios aleatorios durante el proceso de copia. Luego, esta descendencia digital prosigue con la siguiente generación, formando un nuevo acervo de soluciones candidatas, las cuales nuevamente son sometidas a una ronda de evaluación de aptitud.

Las candidatas que han empeorado o no han mejorado con los cambios en su código, son eliminadas, pero de nuevo, las variaciones aleatorias introducidas en la población pueden haber mejorado a algunos individuos, convirtiéndolos en mejores soluciones del problema. De nuevo, se seleccionan y copian estos individuos vencedores en la siguiente generación, con cambios aleatorios, y el proceso se repite.

Algoritmo 2.1. -Algoritmo Genético Típico

```

1  Inicio generación de la población inicial
2  mientras no se cumpla la condición de parada hacer
3  Inicio
4      Reproducción
5          Evaluación
6          Selección
7          Cruce
8          Mutación
9  Fin
10 Fin

```

La expectativa es que la aptitud media de la población se incrementará en cada ronda y, por tanto, repitiendo este proceso cientos o miles de rondas, puedan descubrirse soluciones asertivas del problema.

El problema que confrontan los AG consiste en identificar dentro de un espacio de hipótesis el mejor candidato, donde el mejor candidato es aquel que optimiza una medida numérica predefinida para el problema, llamada adaptación (fitness) [44]. Aunque los detalles de implementación varían entre las diferentes técnicas de la computación evolutiva, todas comparten en general la siguiente estructura [46].

- El algoritmo opera iterativamente, actualizando un conjunto de hipótesis llamada población.
- En cada iteración, todos los miembros de la población son evaluados de acuerdo a una función de adaptación.
- Una nueva población es generada, seleccionando probabilísticamente los individuos de mayor adaptación en la población presente.
- Algunos de estos individuos de mayor adaptación de la población presente pasan intactos a la siguiente generación, otros son modificados usando operadores genéticos (se generan individuos nuevos).

A continuación se estudian algunos aspectos a considerar al usar los AG [43].

1. *Individuos*: Durante los primeros años el tipo de representación utilizada era siempre binario, debido a que se adapta perfectamente a los tipos de operadores genéticos que se utilizan en un AG. Sin embargo, las representaciones binarias no son siempre efectivas, por lo que se empezaron a utilizarse otro tipo de representaciones. En general, una representación ha de ser capaz de identificar las características constituyentes de un conjunto de soluciones. En este orden de ideas, se pueden considerar tres tipos básicos de representaciones binarias, enteras o reales.

2. *Población inicial*: la población inicial de un AG puede ser creada de muy diversas formas: generar aleatoriamente el valor de cada gen para cada individuo, utilizar una función deseada, o generar alguna parte de cada individuo y luego aplicar una búsqueda local, entre otras.

3. *Tamaño de la población*: el proceso evolutivo se basa en las sucesivas modificaciones realizadas a través de un cierto número de generaciones de una población

de individuos. Así, cuanto mayor sea la población, más variedad se obtendrá durante la evolución. El tamaño de la población se ve principalmente afectado por el tiempo que se tarda en calcular la aptitud de un individuo.

4. *Número de generaciones:* la evolución se lleva a cabo modificando los individuos que componen la población actual. Cada ciclo del proceso evolutivo es una evolución, y el AG iterará un número de generaciones dada.

5. *Función aptitud:* es una expresión matemática que debe ser capaz de evaluar la calidad de cualquier individuo de la población.

La regla general para construir una buena función objetivo es que ésta debe reflejar el valor del individuo de una manera “real”, pero en muchos problemas de optimización combinatoria, donde existe gran cantidad de restricciones, buena parte del espacio de búsqueda representan individuos no válidos. Para este caso, se han propuesto varias soluciones. La primera sería la que se podría denominar absolutista, en la que aquellos individuos que no verifican las restricciones no son considerados como tales, y se siguen efectuando cruces y mutaciones hasta obtener individuos válidos; o bien, a dichos individuos se les asigna una función objetivo igual a cero.

Un problema habitual en las ejecuciones de los AG surge debido a la velocidad con la que el algoritmo converge. En algunos casos, la convergencia es muy rápida, lo que suele denominarse convergencia prematura, en la cual el algoritmo converge hacia óptimos locales; mientras que en otros casos, el problema es justo el contrario, es decir, se produce una convergencia lenta del algoritmo. Una posible solución a estos problemas pasa por efectuar transformaciones en la función objetivo. El problema de la convergencia prematura surge a menudo cuando la selección de individuos se realiza de manera proporcional a su función objetivo. En tal caso, pueden existir individuos con una adaptación al problema muy superior al resto, que a medida que avanza el algoritmo “dominan” a la población. Por medio de una transformación de la función objetivo, en este caso, una compresión del rango de variación de la función objetivo, se pretende que dichos “súper individuos” no lleguen a dominar a la población.

6. *Operadores genéticos*: los operadores toman individuos de la población actual y producen nuevos individuos para la generación siguiente, aplicando las transformaciones que impongan los operadores. Los operadores clásicos en los AG son: cruce, mutación.

- a) **Cruce**: El operador de cruce permite realizar una exploración de toda la información almacenada hasta el momento en la población, y combinarla para crear mejores individuos [43]. Una vez seleccionados los individuos, con este operador estos individuos son combinados para producir la descendencia que se insertará en la siguiente generación. Su importancia para la transición entre generaciones es elevada puesto que las tasas de cruce con las que se suele trabajar rondan el 90%. Los diferentes métodos de cruce podrán operar de dos formas diferentes. Si se opta por una estrategia destructiva, los descendientes se insertarán en la población temporal aunque sus padres tengan mejor ajuste. Por el contrario, utilizando una estrategia no destructiva la descendencia pasará a la siguiente generación únicamente si supera la bondad del ajuste de los padres (o de los individuos a reemplazar). La idea principal del cruce se basa en que, si se toman dos individuos correctamente adaptados al medio, y se obtiene una descendencia que comparta genes de ambos, existe la posibilidad de que los genes heredados sean precisamente los causantes de la bondad de los padres.

Al compartir las características buenas de dos individuos, la descendencia, o al menos parte de ella, debería tener una bondad mayor que cada uno de los padres por separado. Si el cruce no agrupa las mejores características en uno de los hijos, y la descendencia tiene un peor ajuste que los padres, no significan que se esté dando un paso atrás. Optando por una estrategia de cruce no destructiva se garantiza que pasen a la siguiente generación los mejores individuos. Si, aún con un ajuste peor se opta por insertar a la descendencia, y puesto que los genes de los padres continuarán en la población, aunque dispersos y posiblemente levemente modificados por la mutación, en posteriores cruces se podrán volver a obtener estos padres, recuperando así la bondad previamente pérdida.

b) **Mutación:** La mutación se considera un operador básico, que proporciona un pequeño elemento de aleatoriedad en el entorno de los individuos de la población. Si bien se admite que el operador de cruce es el responsable de efectuar la búsqueda a lo largo del espacio de posibles soluciones, también parece desprenderse de los experimentos efectuados por varios investigadores que el operador de mutación va ganando en importancia a medida que la población de individuos va convergiendo [47]. El objetivo del operador de mutación es producir nuevas soluciones a partir de la modificación de un cierto número de genes de una solución existente, con la intención de fomentar la variabilidad dentro de la población. Existen muy diversas formas de realizar la mutación, desde la más sencilla, donde cada gen muta aleatoriamente con independencia del resto de genes, hasta configuraciones más complejas donde se tienen en cuenta la estructura del problema y la relación entre los distintos genes.

7. *Reproducción:* los operadores toman individuos de la población actual para alterar su composición genética, este proceso genera nuevos individuos para la siguiente generación. Las transformaciones que imponen los operadores generan nuevos individuos que compiten por quedarse en la población, según sus valores de aptitud (bajas o altas).

8. *Métodos de selección:* el método de selección es el encargado de transmitir y conservar aquellas características de las soluciones que se consideran valiosas a lo largo de las generaciones. El principal medio para que la información útil se transmita es que aquellos individuos mejor adaptados (mejor valor de la función de evaluación) tengan más probabilidades de reproducirse. Sin embargo, es necesario también incluir un factor aleatorio que permita reproducirse a individuos que aunque no estén muy bien adaptados, puedan contener alguna información útil para posteriores generaciones, con el objeto de mantener así también una cierta diversidad en cada población. Algunas de las técnicas de las cuales se dispone son presentadas en [46].

9. *Criterio para terminar la ejecución:* en cuanto al criterio de parada, generalmente viene determinado por criterios a priori sencillos, como un número máximo de generaciones o un tiempo máximo de resolución. Un criterio eficiente está relacionado con

indicadores del estado de evolución de la población, por ejemplo la pérdida de diversidad dentro de la población o no haber mejora en un cierto número de iteraciones. Por lo general, una condición mixta es lo más utilizado, es decir, limitar el tiempo de ejecución a un número de iteraciones y tener en cuenta algún indicador del estado de la población.

En el Capítulo 4, se propone un enfoque en el que método de diagnóstico basado en ARR se optimiza mediante las técnicas inteligentes, que permitan un mejor análisis de diagnosticabilidad, sobre todo en grandes y complejos sistemas de producción, como caso de estudio. Se toma, un sistema de producción de extracción de petróleo de mediante el levantamiento artificial de gas a alta presión.

2.4. MÉTODO DE EXTRACCIÓN DE CRUDO

En Venezuela, el principal proceso de producción industrial es la extracción de petróleo, siendo este la base fundamental de la economía del país. Este proceso está sujeto a continuos cambios en sus variables, debido a esto es de suma importancia el estudio de su comportamiento, de manera de realizar un buen sistema de diagnóstico del mismo [33].

El elemento principal en el proceso de producción de petróleo son los pozos, estos pueden producir de forma natural o artificial. Cuando el pozo pierde la capacidad de levantar el crudo a la superficie deja de producir naturalmente, y para esto se hace necesario aplicar un método de levantamiento artificial. Así los métodos de extracción de crudo de un pozo se dividen en [33]:

- **Flujo Natural:** Cuando existe una tasa de producción donde la energía con la cual el yacimiento ofrece los fluidos hacia el nodo es igual a la energía demandada por el separador, se dice entonces que el pozo es capaz de producir por flujo natural.

Existe una presión de partida de los fluidos en dicho proceso que es la presión estática del yacimiento, P_r , y una presión final o de entrega que es la presión del separador en la estación de flujo, P_s .

- **Flujo Artificial:** Consiste en utilizar una fuente externa de energía para levantar los fluidos del yacimiento desde el fondo del pozo hasta el separador, cuando la demanda de energía de la instalación en el nodo es mayor que la oferta del yacimiento para cualquier tasa de flujo.

Su objetivo, es el de minimizar la presión fluyente en el fondo del pozo (P_r), para aumentar la afluencia de fluidos del yacimiento sin que se generen problemas de producción: arenamiento, conificación de agua, entre otros.

Entre los métodos de levantamiento artificial de mayor aplicación en la industria petrolera se encuentran [33]:

- ✓ Bombeo Mecánico por varilla de succión (BM).
- ✓ Bombeo Electro-sumergible (BES).
- ✓ Bombeo de Cavidad Progresiva (BCP).
- ✓ Bombeo Hidráulico (BH).
- ✓ Levantamiento Artificial por Gas (LAG).



Figura 2.4 -Esquema de producción.

Todos los métodos de levantamiento artificial son usados en los diferentes campos productores, en el caso del occidente de Venezuela, el levantamiento más utilizado en los pozos con automatización integral subsuelo-superficie es el método por LAG. Un esquema del proceso de producción por Levantamiento Artificial por Gas (LAG) se muestra a

continuación (ver Figura 2.4); una vez en superficie el crudo es enviado a una estación de flujo, para que ésta se encargue de separar el flujo multifásico (petróleo, agua, gas, arena), llevándolo a una planta compresora para aumentar su presión, luego es guiado a diferentes múltiples de gas, en el cual se distribuye en los pozos donde se van a inyectar (pozos por levantamiento artificial por gas [33]).

2.4.1. EXTRACCIÓN DE PETRÓLEO POR INYECCIÓN DE GAS

Según [28], el Método de Extracción de petróleo por Inyección de Gas es un método que utiliza gas comprimido como fuente de energía para llevar los fluidos del yacimiento desde el fondo del pozo hasta la superficie; por tanto su principal consideración al momento de su selección en grupo de pozos petroleros, es la disponibilidad de una fuente rentable de gas a alta presión.

El gas inyectado tiene la función de desplazar el fluido hacia la superficie por medio de las siguientes acciones [33]:

- Reducción de la presión que ejerce el fluido en la tubería de producción frente a la formación mediante la disminución de su densidad.
- Expansión del gas inyectado.
- Desplazamiento del fluido por alta presión del gas.

Adicionalmente, el LAG se puede utilizar para lograr los siguientes objetivos:

- Arrancar los pozos que producen por flujo natural.
- Incrementar la producción de pozos que hayan declinado naturalmente, pero que aún producen sin necesidad de utilizar métodos artificial.

Como lo muestra la Figura 2.5, el gas se inyecta a la corriente de fluido por una válvula de levantamiento artificial por gas (válvula de LAG) para levantar los líquidos a la superficie. El peso de la columna de fluido se reduce al ser desplazado los líquidos por el gas mucho más liviano. A medida que el gas se desplaza rápidamente hacia la superficie,

encuentra menos presión en su camino, por lo tanto, sigue expandiéndose y reduciendo aún más la densidad fluyente del fluido. A medida que el gas sigue expandiéndose, se junta con otras burbujas de gas creando grandes espacios de gas, hasta que al llegar a la superficie el gas y el petróleo fluye. Asimismo, es necesario inyectar el gas lo más profundo posible para reducir sustancialmente el peso de la columna, e inyectar la tasa de gas adecuada para que la fricción de la corriente multifásica no anule la reducción de peso.

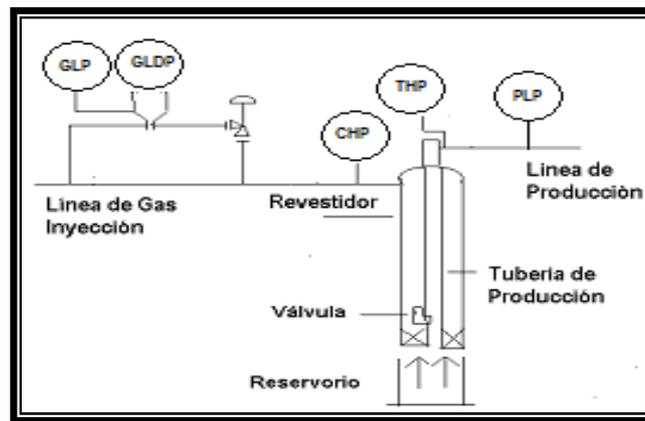


Figura 2.5 -Modelo Levantamiento Artificial por Gas.

La curva de producción de un pozo que produce a través del método de inyección de gas se muestra en la Figura 2.6, la cual indica que a medida que el Flujo de Gas de Levantamiento aumenta (Q_{iny} o FGL), expresado en “MPCDG” (miles de pie cúbico de gas por día), la tasa de producción (Q_{prod}), expresado en “BNPD” (barriles neto de producción diaria) también aumenta hasta alcanzar su máximo valor (Región Estable o Escenario Normal), tal que, incrementos adicionales en la inyección ocasionarían un escenario sobre-inyectado, o por debajo de la inyección necesaria produciría un escenario sub-inyectado, causando en ambos casos una disminución en la producción (Región Inestable) [47].

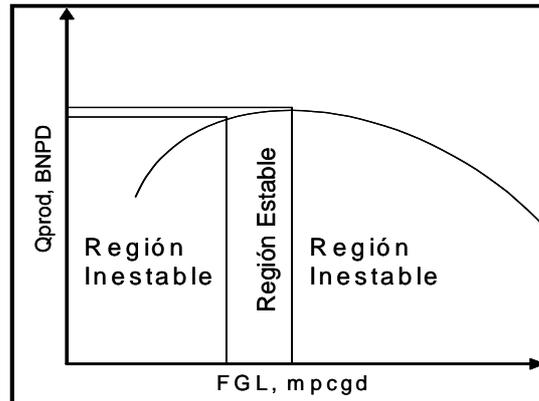


Figura 2.6 -Modelo de comportamiento de un pozo produciendo con un método de inyección de gas.

En trabajos como [29, 30,34, 48] muestran cómo se pudiera estabilizar un pozo por inyección de gas de levantamiento, así como se presentan ciertas ecuaciones que describen el comportamiento de algunos de sus componentes. En [36] es propuesto un sistema de control de inyección en función de la producción, y en [31] se desarrolla una ecuación en función de (Q_{prod}) para modelar el comportamiento de un pozo en condiciones de inyección continua.

2.4.2. VENTAJA, DESVENTAJAS Y APLICACIONES DEL SISTEMA LAG

Algunas ventajas que provee un sistema LAG son: el equipo de subsuelo requerido es sencillo y relativamente de más bajo costo que el de los otros sistemas de levantamiento artificial; es el más flexible entre todos los sistemas de levantamiento artificial; y los equipos instalados en un pozo son capaces de levantar volúmenes desde unos pocos barriles diarios hasta varios miles de barriles diarios, sin necesidad de hacer cambios grandes en ellos.

Cabe destacar que, si se dispone de suficiente volumen y presión de inyección, la flexibilidad del LAG para producir a distintas tasas no es igualada por otros métodos de levantamiento artificial; el levantamiento artificial por gas, no es afectado de manera adversa por la desviación en el fondo del pozo; el gas utilizado en levantamiento es ideal para suplementar el gas de formación y levantar los fluidos en pozos, con relación gas/petróleo relativamente altas. Un sistema LAG es muy apropiado para la producción de

un grupo de pozos en una plataforma costa afuera. Además, los equipos requieren poco mantenimiento, permiten usar el mismo gas que se produce de los pozos y cuando se detecta mal funcionamiento de las válvulas, éstas pueden ser reemplazadas mediante económicos trabajos sin necesidad de sacar tuberías.

Sin embargo, los sistemas LAG también tienen sus desventajas como la complejidad de los procedimientos de cálculo para el diseño y control de las instalaciones, y la necesidad de disponer de relativamente altas a moderadas presiones en las líneas de producción asociadas.

Bajo este contexto, no es recomendable usarlo por razones de índole económica en pozos muy retirados del sistema de distribución de gas a alta presión, ya que el gas usado para levantamiento, es altamente corrosivo, y puede dañar todas las instalaciones. Este método también tiene sus limitaciones en pozos que producen crudos con poco gas de formación, en situaciones con poca disponibilidad de espacio para equipos de compresión de gas en la plataforma, en pozos equipados con tuberías de revestimiento muy viejas, o con líneas de flujo muy largas y de pequeño diámetro.

Dentro de sus aplicaciones, el levantamiento artificial por gas permite obtener altas tasas de producción con una relación buena de gas/fluido del yacimiento, y permite la extracción de petróleo a poca profundidad con pequeños diámetros de tubería.

2.4.3. MODELO DE UN SISTEMA LAG

En [36] realizan un estudio para observar el comportamiento de un pozo de inyección de gas caracterizado por las ecuaciones físicas que rigen el proceso (ver la Figura 2.5), estas están basada en tres variables de estado: x_1 es el flujo de masa de gas en el anular, x_2 es el flujo de masa de gas en la tubería y x_3 es el flujo masa de petróleo en el tubing. Con ellas se pueden definir las primeras ecuaciones.

$$\dot{x}_1 = w_{gc} - w_{iv} \quad (2.22)$$

$$\dot{x}_2 = w_{iv} - w_{pg} \quad (2.23)$$

$$\dot{x}_3 = w_r - w_{po} \quad (2.24)$$

Donde w_{gc} es la tasa de flujo másico de gas inyectado en el anular, que a diferencia de [36] en este estudio equivale a una ecuación física determinada por la ecuación (2.25), w_{iv} es la tasa de flujo másico de gas desde el anular hacia el tubing, w_{pg} es el flujo másico de gas a través de la válvula de choke de producción, w_r es el flujo másico de petróleo proveniente del reservorio por el tubing, w_{po} es el flujo másico de petróleo a través de la válvula de choke y w_{pc} es el flujo másico mezclado en la tubería de producción. Si se modelan los flujos se obtiene:

$$w_{gc} = C_{iv} \cdot \sqrt{gldp(glp - 14,07)} \quad (2.25)$$

$$w_{iv} = C_{iv} \cdot \sqrt{\rho_{a,inj}(P_a - P_{t,inj})} \quad (2.26)$$

$$w_{pc} = C_o \cdot \sqrt{\rho_m(P_t - P_s)} \quad (2.27)$$

$$w_{pg} = \frac{x_2}{x_2 + x_3} \cdot w_{pc} \quad (2.28)$$

$$w_{po} = \frac{x_3}{x_2 + x_3} \cdot w_{pc} \quad (2.29)$$

$$w_{pg} = C_r \cdot (P_r - P_{t,b}) \quad (2.30)$$

Donde C_{iv} , C_o y C_r son constantes de compresibilidad de flujo, $\rho_{a,inj}$ es la densidad del gas en el anular en el punto de inyección, ρ_m es la densidad de la mezcla de petróleo/gas en la parte superior de la tubería, glp es la presión del sistema proveniente de plantas compresoras, $gldp$ es la presión diferencial medida a través de una placa orificio, P_a es la presión en el anular, $P_{t,inj}$ es la presión en la tubería en el punto de inyección de gas, P_t es la presión en la parte superior de la tubería, P_s es la presión en el separador, P_r es la presión en el reservorio, y $P_{t,b}$ es la presión en la parte inferior de la tubería. Las ratas de flujo a través de las válvulas son flujos positivos, y las densidades y las presiones son modeladas por las ecuaciones siguientes:

$$\rho_{a,inj} = \frac{M_0}{RT_a} \cdot P_a \quad (2.31)$$

$$\rho_m = \frac{x_2 + x_3 + \rho_o L_r A_r}{L_t A_t} \quad (2.32)$$

$$P_a = \left(\frac{RT_a}{M_0 V_a} + \frac{gL_a}{V_a} \right) \cdot x_1 \quad (2.33)$$

$$P_t = \frac{RT_t}{M_0} \cdot \frac{x_2 + x_3 +}{L_r A_r + L_t A_t + x_3 v_o} \quad (2.34)$$

$$P_{t,inj} = P_t + \frac{g}{A_t} \cdot (x_2 + x_3) \quad (2.35)$$

$$P_{t,b} = P_{t,inj} + \rho_o g L_r \quad (2.36)$$

Además, M_0 es el peso molecular del gas, R es la constante del gas, T_a es la temperatura en el anular, T_t es la temperatura en la tubería, V_a es el volumen del anular, L_a es la longitud del anular, L_t es el longitud de la tubería, A_t es el área transversal de la tubería por encima del punto de inyección, L_r es la longitud desde el fondo del pozo hasta el punto de inyección de gas, A_r es el área transversal de la tubería por debajo del punto de inyección, g es la constante de gravedad, ρ_o es la densidad del petróleo, y v_o es el volumen específico del petróleo. Finalmente, como el petróleo se considera incompresible, la densidad ρ_o es constante.

2.5. INTERRELACIÓN ENTRE LOS TEMAS TRATADOS EN LA INVESTIGACIÓN

En ocasiones, los métodos típicos como observadores, filtros de Kalman y espacios de paridad, fallan a momento de realizar un análisis de diagnosticabilidad, dada la complejidad de los sistemas, sobre todo en sistemas no lineados, por lo tanto no es posible discernir qué la falla ocurrió con respecto a otra, o incluso que la misma sea detectable.

Por otra parte, durante el análisis con ARR tradicional, pueden existir una gran cantidad de residuos, que no permitan elegir residuos de calidad o los adecuados para el análisis de diagnosticabilidad.

Por esto, es de suma importancia optimizar las técnicas de ARR actuales, y así, brindar un mejor análisis de evaluación de los sistemas y poder distinguir la propiedad de diagnosticabilidad. Es por esto, que en este trabajo utiliza las técnicas inteligentes como los

AG, para evaluar y/o obtener relaciones de redundancia, que permitan garantizar la propiedad de diagnosticabilidad en el sistema.

El uso de los AG permite explorar una población grande de posibles soluciones, muy común en complejos sistemas de producción industrial, tal como el proceso de extracción de petróleo mediante inyección de gas. Permitiendo generar los residuos necesarios e incluso seleccionando los adecuados para detectar y aislar las fallas consideradas

CAPÍTULO III

ANÁLISIS ESTRUCTURAL PARA DETERMINAR LAS PROPIEDADES DE DIAGNOSTICABILIDAD

En este capítulo se presenta una metodología para el estudio de la diagnosticabilidad basada en el análisis estructural, la cual es una de las técnicas de diagnóstico basada en modelos. Adicionalmente, se estudian los problemas de localización de sensores mediante el uso de la técnica de relaciones de redundancia analíticas, basado en trabajos previos. Finalmente, se realizan experimentos con estos trabajos, con el fin de compararlos con el modelo inteligente desarrollado en el Capítulo 4.

3.1. ANÁLISIS ESTRUCTURAL.

Un modelo estructural es una representación de un sistema en el que sólo se utilizan las conexiones entre las variables y ecuaciones, y no las ecuaciones analíticas reales [13]. Los modelos estructurales pueden utilizarse de diferentes maneras. Una forma consiste en hacer un modelo estructural de un sistema en el que el conocimiento sólo es sobre cómo las variables y los estados están conectados, y no en las ecuaciones analíticas reales. Otra forma es hacer un modelo estructural a partir de un sistema analítico conocido, y utilizar el modelo estructural, ya que es menos complejo de usar al analizar el sistema. Este segundo enfoque, es el que se utiliza en la presente investigación. El modelo estructural de un sistema puede ser representado por una matriz estructural o por un grafo bipartito [23].

3.1.1. MATRIZ ESTRUCTURAL

La matriz estructural, es una manera de representar como las E ecuaciones y las variables del conjunto Z están conectadas. Si se considera como ejemplo el siguiente sistema:

Considere el *Ejemplo 1*:

$$e_1: \dot{x}_1 = b_1(x_1, x_2, u, f_1) \tag{3.1}$$

$$e_2: \dot{x}_2 = b_2(x_2, u, f_2) \tag{3.2}$$

⋮

$$e_n: \dot{x}_n = b_n(x_n) \tag{3.3}$$

$$e_{n+1}: y_1 = h_1(x_1, x_2) \tag{3.4}$$

⋮

$$e_{n+m}: y_m = h_m(x_2) \tag{3.5}$$

Donde $x \in \mathbb{R}^n$ son variables desconocidas, $y \in \mathbb{R}^m$ y $u \in \mathbb{R}^c$ son variables conocidas todas pertenecen al conjunto Z . La matriz estructural se muestra en la Tabla 3.1. A menudo, las funciones que caracterizan el modelo son no lineales, representada por b y h , y el conjunto de ecuaciones son representadas por $E = \{e_1, \dots, e_n, e_{n+1}, \dots, e_{n+m}\}$.

Tabla 3.1-Matriz estructural
("x" indica la relacion entre la variable y la ecuación).

E	Variables Desconocidas								Conocidas			
	\dot{x}_1	\dot{x}_2	⋯	\dot{x}_n	x_1	x_2	⋯	x_n	y_1	⋯	y_m	u
e_1	x				x	x						x
e_2		x				x						x
⋮												
e_n				x				x				
e_{n+1}					x	x			x			
⋮												
e_{n+m}						x					x	

Tabla 3.2-Matriz estructural con solo variables desconocidas.

E	Variables Desconocidas							
	\dot{x}_1	\dot{x}_2	⋯	\dot{x}_n	x_1	x_2	⋯	x_n
e_1	x				x	x		
e_2		x				x		
⋮								
e_n				x				x
e_{n+1}					x	x		
⋮								
e_{n+m}						x		

Motivado a esto, se puede mostrar de dos formas diferentes la matriz estructural, una como esta en la Tabla 3.1 y la otra como en la Tabla 3.2, según el conjunto de ecuaciones

que representen el modelo. Generalmente, sólo es interesante considerar las variables desconocidas en la matriz estructural, ya que no se conocen sus estados y deben ser eliminadas en una secuencia de cálculos para obtener residuos (el cual contiene solo variables conocidas).

3.1.2. GRAFO BIPARTITO

Un grafo bipartido es un conjunto de vértices y aristas, el cual, al igual que una matriz estructural, se puede utilizar para representar el modelo de un sistema de manera estructural. El conjunto de vértices consta de dos conjuntos, Z y E , y las aristas, Y , representan la conexión entre una variable y una ecuación. Una arista existe entre el vértice $z_i \in Z$ y el vértice $e_j \in E$ si y sólo si la variable z_i es usada en la ecuación e_j [23].

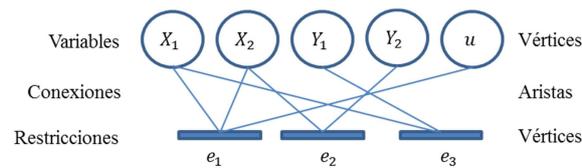


Figura 3.1 -Grafo Bipartito.

El grafo bipartido de la Figura 3.1 muestra una representación de cómo sería el modelo estructural de un sistema.

La idea principal de realizar una representación estructural del sistema es conocer la relación entre las variables del sistema y las ecuaciones que lo caracteriza, con el fin de determinar conjuntos de ecuaciones con un grado de redundancia mayor a uno, y poder así eliminar las variables de estados desconocidas en el sistema, obteniendo una única ecuación analítica que incluya solo variables conocidas. Una de las técnicas para llevar a cabo este análisis es mediante la descomposición canónica del sistema.

3.2. DESCOMPOSICIÓN CANÓNICA DE UN SISTEMA

Como se describió en secciones anteriores, la redundancia es importante en el diagnóstico. Una manera de determinar si existe o no redundancia en un sistema, y de

extraer la parte que contiene esta información redundante, consiste en aplicar la descomposición canónica, la cual divide a cualquier modelo en tres subsistemas con propiedades específicas [23]:

- Una parte sub-determinada $M^- = (E^-, Z^-)$, con menos ecuaciones que variables, no existiendo un emparejamiento completo en E^- ni en Z^- .
- Una parte Justamente-determinada $M^0 = (E^0, Z^0)$, con la misma cantidad de ecuaciones como de variables, donde existe un emparejamiento completo tanto en E^0 como en Z^0 .
- Una parte sobre-determinada $M^+ = (E^+, Z^+)$, con más ecuaciones que variables, existiendo un emparejamiento completo en Z^+ pero no en E^+ .

La descomposición canónica de un sistema consiste en la permutación de las cantidades de ecuaciones por la cantidad de variables para posteriormente dividirlo en los tres sistemas antes mencionados. Un sistema *sobre-determinado* es la parte del sistema que contiene la redundancia, es decir, desde el cual es posible calcular de más de una manera las variables desconocidas [49], y es la parte del sistema de interés para realizar el análisis de diagnosticabilidad. Para estos sistemas es posible construir un generador residual, a partir de un grafo bipartido o una matriz estructural [23], el cual garantiza al menos la detección de fallas en un sistema.

Supongamos, un sistema $M = (E_1, Z_1)$, donde $E_1 \subseteq E$, $Z_1 \subseteq Z$. $Z = X \cup Y$, X son las variables desconocidas en Z_1 .

Definición 8: Sistema Sobre-determinado. Sea el modelo M , el Conjunto M^+ es llamado modelo estructuralmente sobre-determinado (*SO*, por sus siglas en inglés Structurally Overdetermined), si $|E_1| > |X|$. Además, M^0 es estructuralmente justo-determinado si $|E_1| = |X|$, y M^- estructuralmente sub-determinado si $|E_1| < |X|$.

Desde el punto de vista de generación de residuos, se necesita al menos una ecuación más que variables desconocidas en la búsqueda de residuos, lo cual permitiría la

redundancia en el sistema. Con el conocimiento de que un subconjunto propio M_{sp} ¹ es un subconjunto de M ($M_{sp} \subset M$), lo siguiente que se puede definir es un conjunto mínimo estructuralmente sobre-determinado.

Definición 9: Mínimo Sistema Sobre-determinado. Un Subconjunto propio estructuralmente sobre-determinado de M es llamado conjunto mínimo estructuralmente sobre-determinado (MSO, por sus siglas en inglés Minimal Structurally Overdetermined), si en el conjunto de ecuaciones existen más ecuaciones que variables desconocidas y es un sub-conjunto propio de un SO [27, 49]. En particular, $|E_1| - |X| = 1$, sin limitarse a ello.

Sin importar su complejidad, un sistema puede arrojar una gran cantidad de MSO, es decir redundancias analíticas en el sistema. Dada la hipótesis de que los generadores de residuos tienen la posibilidad de ser sensibles a una misma falla, se maximiza la posibilidad de detectabilidad de fallas en un sistema si se encuentra un residuo para cada posible conjunto MSO (ver [27]).

De acuerdo a lo planteado, dado un conjunto de MSO, un sistema debe tener la capacidad de distinguir una simple falla f_i , de una simple falla f_j , tal que las pruebas sometidas a la falla f_i deben ser sensibles solo a él e insensibles a f_j , para poder decir que un sistema cumple con la propiedad de aislabilidad. Para esto, en [21] introducen la noción de la ecuación de soporte de prueba TES (Test Equation Support, por sus siglas en inglés), para determinar la capacidad de aislar las fallas de los residuos, asociando la falla a la ecuación que la caracteriza [21].

Definición 10: Ecuación de Soporte de prueba. Dado un modelo M y un conjunto de fallas consideradas en el modelo $F(M)$, un conjunto de ecuaciones \mathcal{M} son ecuaciones de soporte de prueba (TES) si $F(\mathcal{M}) \neq \emptyset$, \mathcal{M} es un SO y \mathcal{M} corresponde a una parte del modelo dado ($\mathcal{M} \subseteq M$) [21, 49].

¹ M_{sp} : Sub-conjunto propio es una pequeña porción del modelo del sistema que aún cumple con la propiedad de que existen más ecuaciones que variables desconocidas

Si se toma el modelo definido por las ecuaciones de la sección 3.1.1, y se determina que en (3.6) es la (3.1) en el *Ejemplo*, que es donde está contenida la falla, según la **Definición 10**, esta sería la ecuación de soporte de ese modelo.

$$e_1: x_1 = b_1(x_1, x_2, u, f_1) \quad (3.6)$$

Es también de interés el uso de la mínima ecuación de soporte de prueba MTES (Minimal Test Equation Support, por sus siglas en inglés), que de igual manera que un MSO, es el mínimo sub-conjunto de TES con tendencia al mínimo grado de redundancia y que caracteriza un modelo de falla considerada asociada a un SO.

Definición 11: Mínima Ecuación de Soporte de prueba. Dado un modelo, una ecuación de soporte \mathcal{M} es una mínima ecuación de soporte (MTES), si en el conjunto de ecuaciones existen más ecuaciones que variables desconocidas y es un sub-conjunto propio de un $\mathcal{M}' \subseteq M$, tal que $\mathcal{M}' \supsetneq \mathcal{M}$ verifica $F(\mathcal{M}') \supsetneq F(\mathcal{M})$ [21, 49], tendiendo a ser la uno la diferencia entre las cardinalidades del conjunto de ecuaciones y variables desconocidas.

La importancia de los términos que han sido definidos, según [21], es que con MSO y MTES se obtienen residuos eficientes, por los que a través de un generador de residuos se construiría el modelo de diagnóstico FDI de un proceso. Sin embargo, nos interesa obtener un mínimo sub-conjunto de ecuaciones estructuralmente sobre-determinado con la redundancia igual a 1, que contenga una ecuación de soporte de fallas, la cual definiremos como MSOS (por sus siglas en inglés Minimal Structurally Overdetermined with Support), siendo esta definición la clave y el aporte de esta investigación.

Definición 12: Mínimo Sistema Sobre-determinado con Soporte. Un Subconjunto propio estructuralmente sobre-determinado de M es llamado conjunto mínimo estructuralmente sobre-determinado con soporte MSOS, si en el conjunto de ecuaciones en función a la ecuación de soporte solo existe una ecuación más que variables desconocidas $\varphi(\mathcal{M}) = 1$, \mathcal{M} es un SO y \mathcal{M} corresponde a una parte del modelo dado ($\mathcal{M} \subseteq M$). Donde $\varphi(\mathcal{M})$ es la diferencia entre las cardinalidades del conjunto de ecuaciones y variables desconocidas, $\varphi(\mathcal{M}) = |E_1| - |X|$.

La descomposición canónica del sistema, nos brinda la oportunidad de realizar un análisis de diagnosticabilidad, y con el obtener sub-conjuntos de ecuaciones del modelo original, con suficiente información que permitan determinar una relación de redundancia analítica.

3.3. EMPAREJAMIENTO

La herramienta básica para el análisis estructural es el emparejamiento de variables. Un emparejamiento puede ser representado tanto en la matriz estructural como en el grafo bipartido. En una matriz estructural, el emparejamiento selecciona un elemento y sólo uno en cada fila y en cada columna. Cada elemento seleccionado representa una arista del emparejamiento, y ninguna otra arista debe contener la misma variable. Aquellas variables que no son emparejadas, no pueden ser calculadas a partir de las variables de valor conocido, y las variables que están emparejadas de diferentes maneras, es decir, conectadas a varias aristas, originan las relaciones redundantes (RR).

Definición 13: Emparejamiento. Un emparejamiento Ep es una asignación causal que asocia algunas variables del sistema que son consideradas desconocidas (X_{Ep}), con las ecuaciones E_{Ep} a partir de las cuales es posible calcularlas [39]. Un emparejamiento es un subconjunto del modelo M , en el entendido de que ninguna arista tiene vértices comunes.

Definición 14: Emparejamiento Completo. Un emparejamiento Ec es llamado completo con respecto a E , si toda $e \in E$ es el punto final de una arista del grafo bipartido G , es decir, $|E_c| = |E_{Ep}|$. Un emparejamiento es llamado completo con respecto a X , si toda $x \in X$ es el punto final de una arista de G , es decir $|X_{Ep}| = |E_{Ep}|$ [39].

Definición 15: Emparejamiento Máximo. Un emparejamiento Ep es llamado máximo, si no existe otro emparejamiento Ep_2 tal que $|Ep_2| > |Ep|$, o sea que no es posible agregar una arista más a Ep sin violar la propiedad de vértices comunes [39].

Los emparejamientos determinan el sub-conjunto de ecuaciones con información suficiente para obtener las relaciones de redundancia analítica, con el fin de eliminar todos los estados desconocidos del sub-conjunto emparejado, del *Ejemplo 1* considerado al inicio de la sección una posible solución se muestra en la Tabla 2.4.

Tabla 2.3-Matriz estructural de un sub-conjunto de MSOS.

E	Variables Desconocidas								Conocidas			
	\dot{x}_1	\dot{x}_2	...	\dot{x}_n	x_1	x_2	...	x_n	y_1	y_m	u	f_1
e_1	x				x	x					x	x
e_{n+1}					x	x			x			
e_{n+m}						x				x		

La Tabla 2.4 muestra un posible emparejamiento, en el cual mediante una secuencia de cálculos finitos, se puede eliminar todas las variables desconocidas y obtener una única función analíticamente redundante que contenga solo variables conocidas, todo mediante la metodología de un MSOS.

3.4. RELACIONES DE REDUNDANCIA ANALÍTICA.

A partir de las redundancias es posible construir las ecuaciones de diagnóstico llamadas ARR, aplicando un procedimiento hacia atrás, con la finalidad de eliminar las variables desconocidas involucradas en las relaciones de redundancia, hasta que únicamente cada ecuación esté en función solamente de variables conocidas [12].

Dado que en MBD es fundamental un modelo matemático, consideremos el *Ejemplo 1* en la Sección 3.1.1 como el modelo M de un sistema, que se utilizara a lo largo de esta sección.

En ese ejemplo, x son los vectores de las variables desconocidas o no observadas $x \in \mathbb{R}^n$, u, y son los vectores de control y de salidas, respectivamente, $u \in \mathbb{R}^c$, $y \in \mathbb{R}^m$, y ambas pertenecen al conjunto de variables medidas o calculadas $Z = \{u_1, \dots, u_c, y_1, \dots, y_m\}$. Por otra parte, el conjunto de ecuaciones esta denotado por una cantidad de ecuaciones, definidas en el conjunto de ecuaciones $E = \{e_1, \dots, e_p\}$, donde $p = n + m$, arrojando el

modelo $M(E, X, Y)$. La relación entre las ecuaciones de un modelo y las variables está determinada por b y h , las cuales generalmente son funciones polinomiales.

Los componentes Z pueden ser derivados hasta un orden de l , lo que denota $\bar{Z} = \partial Z^l$ contenidos en alguna ecuación de M . Las variables observadas se pueden derivar en el tiempo hasta un orden no especificado $\bar{u}, \bar{y} = \{u_1, \dot{u}_1, \ddot{u}_1, \dots, u_c^l, y, \dot{y}, \ddot{y}, \dots, y_m^l\}$, tal que permiten eliminar todos los estados desconocidos de M , y obtener el residuo R . q es la función, generalmente polinomial, cuyo valor es nulo en un sistema libre de fallas, y contiene únicamente variables conocidas (\bar{u}, \bar{y}) [52]. Los residuos tienen las características como (3.7).

$$R = q(\bar{u}, \bar{y}) \quad (3.7)$$

La detectabilidad de fallas es determinada al momento que el ARR en presencia de una falla muestre un valor diferente a nulo. La aislabilidad es determinada si en la evaluación del comportamiento de un conjunto de ARR, se puede distinguir que falla ha ocurrido con respecto a un conjunto de fallas. En general:

- Un ARR es una función del sistema que solo contiene variables conocidas del sistema.
- Un ARR se usa para determinar si contienen la información suficiente para detectar una falla considerada.

Hay que tener en cuenta que los ARR son descripciones del sistema basadas en la relación entrada-salida (aunque en algunos casos existen relaciones de salida-salida, por ejemplo, cuando la redundancia está presente entre los sensores del sistema).

La *auto-redundancia*. Para la j -ésima salida, $j \in J = \{1, \dots, m\}$, de (3.4) proviene (3.8), lo cual permite la eliminación de estados desconocidos del sistema:

$$y_j = h_j(x, u) \quad (3.8)$$

En M , debe existir al menos una derivada con características, $\dot{y}_j = (\partial h_j / \partial x)b + (\partial h_j / \partial u)\dot{u}$, y puede ser probado que para todo $(j, s) \in J \times N$, existe una función polinomial g_s^j sobre R , tal que, $y_j^{(s)} = g_s^j(x, \bar{u}^{(s)})$.

Sea $g_0^j = h_j$ y $G_s^j = \left((g_0^j)^T (g_1^j)^T \dots (g_s^j)^T \right)^T$, entonces, un residuo r_s^j será una matriz Jacobiana de rango genérico $J_x(G_s^j)$.

Para cualquier arreglo $s \in N$, existe un ARR exactamente si $s + 1 - r_s^j$, originando la ecuación (3.9).

$$w_k(\bar{y}_j^{(s)}, \bar{u}_j^{(s)}) = 0, \quad k = 1, \dots, s + 1 - r_s^j \quad (3.9)$$

Los cuales son independientes en el sentido de la matriz Jacobiana representada con la ecuación (3.10).

$$J_{\bar{y}_j}(W) = \begin{bmatrix} (\partial w_1 / \partial \bar{y}_j^{(s)})(\bar{y}_j^{(s)}, \bar{u}_j^{(s)}) \\ \vdots \\ (\partial w_{s+1-r_s^j} / \partial \bar{y}_j^{(s)})(\bar{y}_j^{(s)}, \bar{u}_j^{(s)}) \end{bmatrix} \quad (3.10)$$

Es de rango $s + 1 - r_s^j$ para casi cualquier vector $(\bar{y}_j^{(s)}, \bar{u}_j^{(s)})$, el cual satisface a (3.9). Entonces, $\exists r^j \in N, r^j \leq n$, tal que.

$$r_s^j = \begin{cases} s + 1, & s < r^j \\ r^j, & s \geq r^j \end{cases} \quad (3.11)$$

Por lo tanto, un ARR existe solo si, $s \geq r^j$ (obviamente, $s + 1 - r_s^j = 0$ cuando $s < r^j$). Un r^j tiene la dimensión algebraica de la salida del sistema según las ecuaciones del modelos, es decir, de dimensión m .

La *inter-redundancia*. Los ARR que envuelven varias salidas son llamados relaciones de inter-redundancia, que no pueden ser inferidos con la auto-redundancia, es decir, con

una redundancia directa, por lo tanto, podemos inferir los residuos mediante una redundancia temporal de la siguiente manera.

Sea $(s_1, s_2, \dots, s_m) \in N^m$ con $s_j < r^j \forall j \in J$, y sea $r_{(s_1, s_2, \dots, s_m)}$, que pertenezca al rango genérico de $[J_x^T(G_{s_1}^1) \dots J_x^T(G_{s_m}^m)]^T$. Entonces, existe exactamente $n = \sum_{j=1}^m s_j + m - r_{(s_1, s_2, \dots, s_m)}$ cantidades de ARR independientes, incluidos en $\bar{y}_1^{(s_1)}, \dots, \bar{y}_m^{(s_m)}, \bar{u}$ en la forma de;

$$w_k(\bar{y}_1^{(s_1)}, \dots, \bar{y}_m^{(s_m)}, \bar{u}) = 0, \quad k = 1, \dots, n \quad (3.12)$$

Con la propiedad de la matriz (3.13):

$$\text{rango} \begin{bmatrix} (\partial w_1 / \partial \bar{y})(\bar{y}, \bar{u}) \\ \vdots \\ (\partial w_n / \partial \bar{y})(\bar{y}, \bar{u}) \end{bmatrix} = n \quad (3.13)$$

Para casi cualquier vector $\bar{y} = (\bar{y}_1^{(s_1)}, \dots, \bar{y}_m^{(s_m)}), \bar{u}$ el cual satisface a (3.12). Entonces, $\forall (s_1, \dots, s_m) \in N^m$ con $s_j < r^j \forall j \in J$ existe:

$$r_{(s_1, s_2, \dots, s_m)} \leq \text{Min} \left(\sum_{j=1}^m s_j + m, n \right) \quad (3.14)$$

Cuando se cumple la igualdad $\sum_{j=1}^m s_j + m = n + 1$, la elección minimiza el orden más alto de la derivada para cada salida, ya que debe existir una sola derivada en cada ARR.

Para la obtención final del ARR, se realiza el cálculo para la eliminación de estados en el sistema a partir de $\bar{y}_j^{(s_j)} = g_s^j(x, \bar{u}^{(s)})$, $j \in J = \{1, \dots, m\}$, con el fin de que el residuo sea insensible a los estados desconocidos.

El enfoque ARR es usado en este trabajo para eliminar las variables desconocidas. Se diferencia de esta manera de los otros métodos, como los observadores o filtros Kalman, los

cuales buscan estimar las variables desconocidas, lo que dificulta el análisis en grandes y complejos sistemas. Además, se diferencia del método de espacios de paridad, ya que este último es muy complicado utilizar para el análisis de diagnosticabilidad en sistemas no lineales.

En trabajos como [52], han obtenido la expresión analítica de un ARR para sistemas lineales, que garantiza la eliminación de estados desconocidos. En [12] muestran una técnica para obtener ARR en sistemas no lineales, y en el Capítulo 4 se utilizan técnicas inteligentes para obtener ARR en sistemas no lineales, con la información suficiente para detectar y aislar las fallas consideradas.

A partir de las definiciones hasta ahora mencionadas, es importante constatar que existe una relación exacta entre un ARR (residuo) y un MSOS, con el cual se puede detectar una falla, tal que todos los estados desconocidos son eliminados mediante una secuencia de cálculos.

Ejemplo 2: Considerar el siguiente sistema continuo.

$$e_1: \dot{x}_1 = -x_1 - 5x_2 + u + f_1 \quad (3.15)$$

$$e_2: \dot{x}_2 = -x_2 + u + f_2 \quad (3.16)$$

$$e_3: y_1 = x_1 + x_2 \quad (3.17)$$

$$e_4: y_2 = x_2 \quad (3.18)$$

Es posible encontrar 2 conjuntos de MSOS en el sistema, y así encontrar 2 relaciones de redundancia analítica, lo que permite detectar las fallas consideradas. La matriz estructural de los conjuntos de MSOS se pueden observar en la Tabla 3.4 y la Tabla 3.5.

Tabla 3.4-Matriz estructural del MSOS1.

	\dot{x}_1	x_1	x_2
e_1	x	x	x
e_3		x	x
e_4			x

$$R_1: = \dot{y}_1 - \dot{y}_2 - y_1 + 4y_2 - u - f_1 \quad (3.19)$$

Tabla 2.5-Matriz estructural del MSOS2.

	\dot{x}_2	x_2
e_2	x	x
e_4		x

$$R_2 := -\dot{y}_2 + y_2 + u + f_2 \quad (3.20)$$

En total 2 MSOS fueron encontrados, mostrados en las Tablas 2.3 y 2.4, donde existe una ecuación más que variables desconocidas. El emparejamiento de variables conocidas permite alcanzar 2 relaciones de redundancia analítica, logrando alcanzar la detectabilidad de los fallos.

En específico, a partir de las relaciones de redundancia es posible aplicar un procedimiento recursivo, mediante el cual las variables desconocidas de las relaciones de redundancia se pueden calcular con base a las variables conocidas, obteniéndose de esta forma las ARR como en (3.19) y (3.20).

3.5. MATRIZ DE FIRMA DE FALLAS

Iniciamos con la definición de varios conceptos vinculados a la matriz de firma de fallas, los cuales son necesarios tener claro para el desarrollo del modelo propuesto en esta investigación.

Definición 16: Sistema en Modo de Fallas. Es la representación del sistema con un comportamiento anómalo al diseñado, es decir, bajo la presencia de una falla [17].

Definición 17: Firma de Fallas. Dado un conjunto de residuos de un sistema, cada falla es sensible a uno o varios residuos, generando así firmas [13]. En específico, el conjunto de ARR que son sensibles a *un modo de falla* se le llama *firma de falla*. Esto es así si la falla es detectable.

Definición 18: Matriz de Firma de Fallas. Para determinar la firma de falla de cada modo de falla se construye la matriz de firma de fallas (MFF). Ella es una matriz obtenida

por la concatenación de todas las posibles firmas de fallas (una para cada falla). Cada fila corresponde a una ARR y cada columna a un modo de falla. Un “1” en la posición (k, s) indica que la falla k es detectable por el ARR s . Por tal motivo, es posible aislar todas las fallas en un sistema cuando cada sensibilidad o firma es linealmente independiente a otra [13], cumpliendo así con la propiedad de diagnosticabilidad. Siguiendo con el ejemplo anterior, una matriz de falla es construida en la Tabla 3.6.

Analizando la Tabla 3.6, las columnas representan las fallas consideradas, y la aislabilidad viene dada por la independencia lineal de las columnas, lo cual permite identificar cual falla ha ocurrido entre todas las fallas detectables.

Tabla 3.6 -Matriz de firma de fallas.

	f_1	f_2	...	f_ℓ
R_1	1			1
R_2				1
\vdots				
R_g		1		

Teorema 1: Detectabilidad basado en MBD. Sea una MFF con un conjunto de fallas, si existe la presencia de f_i , la misma es detectable si en el análisis de sensibilidad de los residuos existe un $R_i \neq 0$, como consecuencia $S_i \neq \emptyset$.

Prueba del Teorema 1: Sea una MFF, si al analizar la misma, existe al menos un “1” lógico en la columna que representa la f_i , se puede concluir que al menos un residuo es sensible a f_i , lo que hace posible la detección de la misma.

Teorema 2: Aislabilidad basado en MBD. Sea un conjunto de falla donde $f \in \mathbb{R}^\ell$ representadas en una MFF, la aislabilidad se determina si en el análisis todas las columnas son linealmente independiente entre todas ellas.

Prueba del Teorema 2: En coherencia con el análisis de la MFF, se puede concluir que el sistema posee una aislabilidad completa si las columnas en la MFF son linealmente

independiente, permitiendo separar a f_i de entre todas, donde $i = \{1, \dots, \ell\}$, e incluso la intersección de todas las posibles combinaciones de fallas debe ser igual a vacío.

En coherencia con el *Ejemplo 2*, la Tabla 3.7 muestra una MFF con los resultados obtenidos en las ecuaciones (3.19) y (3.20).

Tabla 3.7-Matriz de Firma de Fallas.

<i>Arr</i>	f_1	f_2
R_1	1	
R_2		1

Por lo antes mostrado, podemos decir que la firma que causa una falla en un dado residuo permite la detección de la misma al ser diferente de cero, y las diferencias entre todas las firmas de fallas consideradas hacen posible determinar qué falla á ocurrido.

Existen algoritmos computacionales para encontrar la ecuación de residuo final (ver [20]). Sin embargo, el propósito de este trabajo es obtener un sub-conjunto de ecuaciones con información suficiente para determinar la sensibilidad de los residuos frente a un conjunto de fallas, no es propósito el obtener la función analítica que caracteriza el residuo.

En complejos sistemas, con grandes cantidades de redundancia, se necesitan algoritmos que permitan obtener residuos de manera eficiente. En este trabajo en particular se usa el algoritmo propuesto en [21] para toda la fase de análisis de MTES (algoritmo 3.1). El algoritmo 3.1 se encuentra basado en la definición 11, donde \mathcal{M} es un sub-modelo parcial de M , siendo una ecuación de soporte que pertenece a la parte sobre-determinada M^+ (ver línea 2 del algoritmo 3.1). Ya que existen fallas asociadas a \mathcal{M} , en la línea 4 se invoca al algoritmo principal descrito en el algoritmo 3.2.

Algoritmo 3.1. -Algoritmo para encontrar MTES desarrollado en [21].

```

function S = MTES (M)
1  S = 0;
2   $\mathcal{M} = \{\{e\} | e \in M^+\};$ 
3  if  $F(\mathcal{M}) \neq 0$ 
4  S = FindMTES( $\mathcal{M}, \mathcal{M}$ );
5  end

```

Algoritmo 3.2. -Algoritmo principal para encontrar MTES desarrollado en [21]

```

function S = FindMTES( $\mathcal{M}, R$ )
1  Select an  $E \in \mathcal{M}$  such that  $F(E) \neq 0$ ;
2  if  $e_f \in \bigcup_{E' \in [E]} E'$  for all  $f \in F(\mathcal{M})$ 
   %  $\mathcal{M}$  is a MTES
3  S =  $\{\bigcup_{E \in \mathcal{M}} E\}$ ;
4  else
5   $R' = 0$ ;  $\mathcal{M}' = \mathcal{M}$ ;
   % lump the structure  $\mathcal{M}'$  and create  $R'$ 
6  while  $F(R) \neq 0$ 
7  Select an  $E \in R$  such that  $F(R) \neq 0$ ;
8   $\mathcal{M}' = (\mathcal{M} \setminus [E]) \cup \{\bigcup_{E' \in [E]} E'\}$ ;
9  if  $[E] \subseteq R$ 
10  $R' = R' \cup \{\bigcup_{E' \in [E]} E'\}$ ;
11 end
12  $R = R \setminus [E]$ ;
13 end
14 S = 0;
   % make the recursive call
15 while
16 Select an  $E \in R'$ ;
17  $R' = R' \setminus [E]$ ;
18 S = S  $\cup$  FindMTES( $\mathcal{M}' \setminus \{E\}, R' \cup R$ );
19 end
20 end

```

En la línea 1 del algoritmo 3.2 se selecciona la familia de ecuaciones sensibles a una falla E' . Si es un MTES (definido por el argumento R) el mínimo sub-conjunto de ecuación que pertenece a \mathcal{M} agrupa los resultados en S , de lo contrario el algoritmo crea en la línea 5 \mathcal{M}' , el cual es un modelo parcial de \mathcal{M} , para entrar en un bucle (ver líneas 6 al 13). En ese bucle remueve ecuaciones $R = R \setminus [E]$ (ver línea 12), y crea modelos parciales hasta que $R \neq 0$. Finalmente, hace una llamada recursiva en la línea 18 evaluando cada una de las

ecuaciones de soportes en el sistema, para posteriormente construir modelos parciales de manera de encontrar los MTES necesarios para cumplir con la detectabilidad y aislabilidad del sistema, almacenando los resultados en S (ver línea 18).

En oportunidades, la información que proviene de las mediciones del sistema no es suficiente para generar residuos que permitan distinguir entre un conjunto de fallas, o incluso poder detectarlas, lo que hace imprescindible tener una técnica para la localización de nuevos sensores que ayuden a resolver estos inconvenientes, incrementando las variables observadas y así la redundancia del mismo. En ese sentido, cualquier enfoque para el análisis de diagnosticabilidad en un sistema, debe determinar si en el análisis del mismo se pueden detectar y aislar todas las fallas, y definir donde se deberían incorporar nuevos sensores en el caso que no pueda.

Ahora bien, las técnicas clásicas de localización de sensores no siempre permiten obtener los mejores resultados, ya que no exploran las posibles alternativas de configuración de sensores. Eso es particularmente importante en los procesos de producción, donde existen grandes cantidades de redundancias analíticas, lo que dificulta la identificación de los residuos que son afectados por las fallas, y la construcción de las firmas de fallas.

3.6. LOCALIZACIÓN DE SENSORES

La eficiencia de un conjunto de sensores de un sistema se puede medir por el grado de diagnosticabilidad que proporciona. En particular, el mismo nivel de diagnosticabilidad se puede obtener para diferentes configuraciones de sensores. Continuando con el método de análisis estructural, el problema de localización de sensores se puede resolver usando una representación estructural del modelo tal como se utiliza en [6]: La representación estructural de un conjunto E de ecuaciones con X incógnitas es un gráfico bipartito, tal como se ha descrito a lo largo de la investigación.

Sea E y F un conjunto de ecuaciones y un conjunto de fallas individuales, respectivamente. Sin pérdida de generalidad, es posible suponer que un fallo sólo puede violar una ecuación. Si una señal de fallo f aparece en más de una ecuación, simplemente se reemplaza en las ecuaciones con una variable nueva f_k y se añade la ecuación $f = f_k$, que será entonces la única ecuación violada por la falla. Sea $e_f \in E$ la ecuación que podría ser violada por una falla $f_k \in F$.

Ejemplo 2: Del ejemplo 2. $f_1 = e_1$

Una falla f es detectable si existe una observación que sea consistente con el sistema en modo de falla f , e inconsistente con el sistema en modo normal. Esto significa que una falla es detectable si puede violar una ecuación, y esta ecuación está contenida en la parte estructuralmente sobre-determinado de M [37].

En un modelo estructural del sistema donde hay fallos que no pueden ser detectados, se pueden añadir sensores para aumentar la observabilidad del sistema. Si se supone que un sensor y_{p+1} se ha añadido para la medición de x_n , se incluyen en el modelo como $e_{m+1}: y_{p+1} = x_n$.

De esta manera, se aspira que las fallas no detectadas puedan ser detectables, a través de un residuo que sea capaz de detectarla porque la redundancia del sistema se incrementa. Una suposición general del enfoque es que el modelo no contiene ninguna parte indeterminada. Sin perder la generalidad, se supone también que una falla afecta a no más de una ecuación, y que cada sensor mide una variable desconocida.

Un objetivo del algoritmo propuesto en [7] es encontrar un mínimo conjunto de sensores que alcanzan estructuralmente la detectabilidad y la aislabilidad de fallas en un conjunto determinado con exactitud de ecuaciones. En este orden, se puede determinar qué parte exactamente del modelo se convierte en sobre-determinado cuando se añade un sensor. El siguiente algoritmo formaliza la discusión anterior.

Sea E un conjunto determinado con exactitud de ecuaciones, F el conjunto correspondiente a las fallas, $P \subseteq X$ el conjunto de localización de sensores posibles, y E_s el conjunto de ecuaciones que describe los sensores adicionales establecidos. El siguiente algoritmo garantiza la detectabilidad y aislabilidad, incrementando la parte sobre-determinada del modelo. En este algoritmo, γ es el mínimo conjunto de sensores adicionales, de tal manera que las fallas se vuelvan detectables y aislabilidad en $M_e = M' \cup M_s$, dónde M_e es la parte extendida del modelo que incluye los sensores [7].

Donde en la línea 2, el Algoritmo 3.3 comprueba la parte justamente-determinada del sistema M , y en la línea 3 determina todas las fallas en M^0 . A continuación, se comprueba la detectabilidad de M^0 y el conjunto actual de sensores es establecido. Las líneas 6 y 12 describen el procedimiento para añadir nuevos sensores, creando M_e como el nuevo modelo con los nuevos sensores y fallas F_e incluidas en este modelo. Además, el algoritmo verifica la propiedad de aislabilidad y el nuevo conjunto de sensores. Esto se repite hasta alcanzar la propiedad de aislabilidad de M_e . La idea es obtener un número mínimo de sensores para el diagnóstico de las fallas F_e .

Algoritmo 3.3. -Algoritmo de localización de sensores propuesto en [7].

```

function  $\Upsilon = \text{Sensorplacement}(M, F, P)$ 
1   $\Upsilon = \emptyset$ ;
2   $M^0 = \text{just-determined part of } M$ ;
3   $F^0 = \text{the set of faults } F \text{ included in } M^0$ ;
4   $D = \text{Detectability}(M^0, F^0, P)$ ;
5   $\Upsilon_d = \text{minimalsensorset}(D)$ ;
6  for  $\Upsilon_i \in \Upsilon_d$ 
7      create the extended model  $M_e = M \cup M_s$ ;
8       $F_e = \text{the faults included in } M_e$ ;
9       $D = \text{Isolability}(M_e, F_e, P)$ ;
10      $\Upsilon_d = \text{minimalsensorset}(D)$ ;
11      $\Upsilon = \Upsilon \cup \{\Upsilon_i \cup \Upsilon' \mid \Upsilon' \in \Upsilon_i\}$ ;
12 end
13 Delete nonminimal sensor sets in  $\Upsilon$ ;

```

Esta técnica permite obtener un mínimo conjunto de sensores, y con ello de ARR, basada en la idea de MTES. Sin embargo, el algoritmo estructura los resultados en función al orden en el que se introducen los datos, lo que no siempre permite obtener los mejores resultados (no explora las posibles alternativas de introducción de nuevos sensores).

3.7. ANÁLISIS DE DIAGNOSTICABILIDAD CON MÉTODOS FDI PARA PROCESOS CONTINUOS.

Un aspecto importante en este dominio es determinar la propiedad diagnosticabilidad del proceso. El análisis de diagnosticabilidad de sistemas continuos, permite estudiar los aspectos de la detectabilidad y aislabilidad de fallas. En esta sección, se utilizan los métodos FDI expuestos en [21, 27] en un proceso continuo y para el caso de estudio.

3.7.1. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN PROCESO CONTINUO

En esta sección se realiza el análisis de diagnosticabilidad en un ejemplo común en la literatura, utilizando el algoritmo propuesto en [21]. Considere el siguiente sistema como *Ejemplo 3*. La Figura 3.2 muestra el modelo estructural en forma de grafo bipartito.

Ejemplo 3; Considere el siguiente sistema continuo.

$$e_1: \dot{x}_1 = -x_1 + u + f_1 \quad (3.21)$$

$$e_2: \dot{x}_2 = x_1 - 2x_2 + x_3 + f_2 \quad (3.22)$$

$$e_3: \dot{x}_3 = x_2 - 3x_3 \quad (3.23)$$

$$e_4: y_1 = x_2 + f_3 \quad (3.24)$$

$$e_5: y_2 = x_2 + f_4 \quad (3.25)$$

$$e_6: y_3 = x_3 + f_5 \quad (3.26)$$

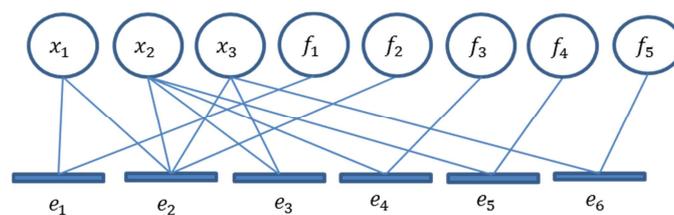


Figura 3.2 - Grafo bipartito del ejemplo anterior.

La técnica utilizada es explicada en la Sección 3.1 del presente trabajo. A continuación, se muestran los resultados que se obtienen al ejecutar el algoritmo propuesto en [21]. Se puede observar en la Tabla 3.8 que se encuentran 6 MTES, para detectar todas las fallas del ejemplo, y en la Tabla 3.9 se muestra la matriz de firma de fallas que se puede construir a partir de los resultados de este algoritmo [21].

Tabla 3.8- Conjunto de MTES propuesto por el algoritmo desarrollado en [21].

MTES PARA TODAS LAS FALLAS	
MTES	[3 5 6]
	[3 4 6]
	[4 5]
	[1 2 3 6]
	[1 2 3 5]
	[1 2 3 4]

El algoritmo encuentra todos los MTES necesarios para detectar todas las fallas consideradas, demostrando que funciona. Ahora bien, en la Tabla 3.9 se puede observar que f_1 y f_2 no son aislable una de la otra, dado que son linealmente dependiente.

Tabla 3.9- Matriz de firma de fallas resultado del algoritmo desarrollado en [21].

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	0	0	1
Arr_2	0	1	1	0	1	0
Arr_3	0	0	0	0	1	1
Arr_4	0	1	1	1	0	0
Arr_5	0	0	0	1	1	0
Arr_6	0	0	0	1	0	1

3.7.2. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN POZO LAG CON DOS FALLAS

La mayoría de los procesos de producción de petróleo y gas requieren supervisión y control constante. En particular, es necesario el diagnóstico y la detección temprana de fallas, con el fin de tener tiempo suficiente para contrarrestar las consecuencias que podrían ocasionar estas fallas; es por esto, que en esta sección se realiza un análisis de diagnosticabilidad en un pozo de levantamiento artificial.

Para esto, se identifica el modelo matemático del caso de estudio, y posteriormente su modelo estructural. El análisis de diagnosticabilidad se basa en aproximaciones de relaciones de redundancia analíticas y en generación de residuos comparando el comportamiento del proceso con el modelo a través de las variables observadas. Así, con el análisis matemático descrito en la sección 2.4 se identifican las ecuaciones que rigen el

proceso las ecuaciones que van desde (2.21) hasta (2.35), y se extiende con las ecuaciones (3.27) hasta la (3.35) [30, 51] definidas más abajo. En particular, se determina la detectabilidad y aislabilidad de dos fallas: f_1 (falla en el flujo de gas inyectado en el anular) y f_2 (falla en el flujo mixto en la línea de producción), utilizando las técnicas desarrolladas en [21, 27].

En la práctica, las mediciones de las variables de fondo de pozo no están disponibles o no son fiables por naturaleza. De esta manera, en este trabajo se asume que las mediciones se realizan sólo en la parte superior del pozo, en el anular y el cabezal de salida del tubing, con el fin de determinar las dos fallas. El flujo de una sola fase en el anular se mide con precisión basado en la presión y la temperatura medida. Además, se calcula x_1 . También se obtiene la presión en la tubería de producción a nivel del separador, debido a que un sistema de control mantiene la presión en la entrada del separador en la estación de flujo. Para definir las dos variables restantes, se miden la presión en la parte superior de la tubería y el flujo de producción a través de la válvula reguladora.

El conjunto de ecuaciones mostradas a continuación es la relación entre las ecuaciones y las variables medidas en el modelo definido en la Sección 2.4 de este trabajo, y su comportamiento será utilizado también como insumo por el generador de residuos.

$$y_1 = x_1 \quad (3.27)$$

$$y_2 = P_{ai} \quad (3.28)$$

$$y_3 = P_t \quad (3.29)$$

$$y_4 = P_s \quad (3.30)$$

$$y_5 = P_{glp} \quad (3.31)$$

$$y_6 = P_{glap} \quad (3.32)$$

$$y_7 = P_r \quad (3.33)$$

$$y_8 = P_m \quad (3.34)$$

$$y_9 = w_c \quad (3.35)$$

Con el fin de evaluar los resultados, se utilizaron las ecuaciones anteriores y las definidas en la Sección 2.4, las cuales rigen el sistema [24, 53] para desarrollar un modelo del pozo en Simulink, la Tabla 3.10 muestra los valores de la coeficientes involucrados en el proceso. En este modelo, también se construyeron elementos para simular las fallas que se desean detectar con las variables observadas. La Figura 3.3 muestra el comportamiento

normal del pozo. La línea roja es la cantidad de petróleo en el tubing, la línea azul es la cantidad de gas en el espacio del anular, finalmente, la línea verde es la cantidad de gas en el tubing.

Tabla 3.10- Coeficientes constantes.

Parámetro	Valor	Unidad
M_o	0.028	Kg/mol
R	8.31	J/Kmol
G	9.81	m/s^2
T_a	293	K
L_a	0.907	M
V_a	22.3×10^{-3}	m^3
ρ_o	1,000	Kg/m^3
p_r	2.9×10^5	Pa
L_r	14	M
A_r	0.314×10^{-3}	m^2
C_{iv}	1.60×10^{-6}	m^2
C_{pc}	0.156×10^{-3}	m^2
C_r	12×10^{-6}	m^2

Durante la búsqueda de los residuos, es bueno saber cuáles son las cualidades que hacen a un generador de residuos bueno. Hay una serie de factores que se pueden tomar en consideración, en particular, en el caso presentado en la presente investigación, es la capacidad de detección y aislamiento de fallas.

La detección se consigue si hay residuos sensibles a las fallas consideradas en el sistema. Si se alcanza la detectabilidad de fallas, entonces, se examina el aislamiento de fallas. En esta sección, continuando con la técnica descrita al inicio de este capítulo, se calculan los MTES utilizando el algoritmo propuesto en [21], sobre la base de las variables observables actualmente en el caso de estudio.

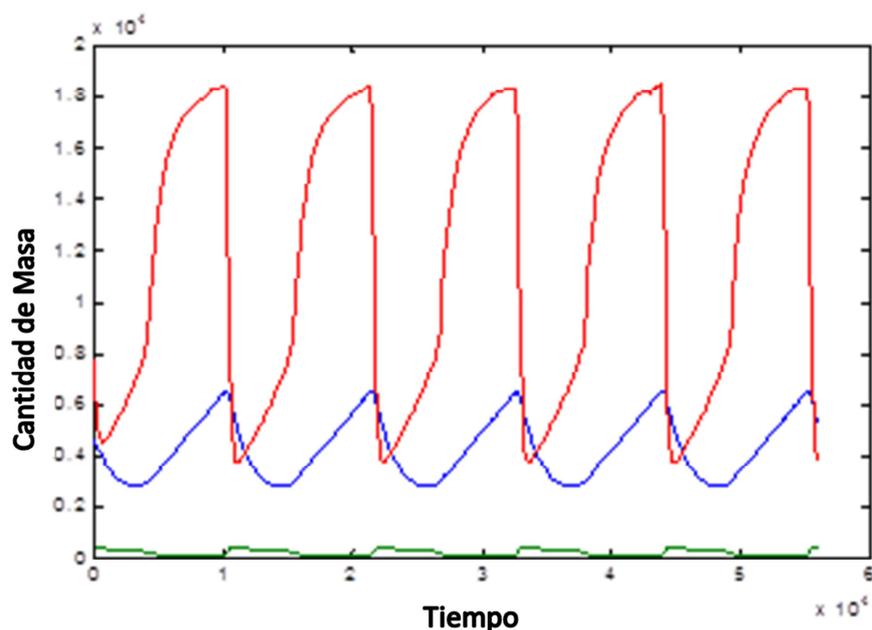


Figura 3.3- Comportamiento del pozo en estado normal.

La Figura 3.4 muestra la matriz de incidencia original del análisis estructural para un pozo de levantamiento artificial por gas [24]. La matriz indica la relación entre las variables (eje horizontal) y ecuaciones (eje vertical), es decir, al sistema de ecuaciones del problema bajo estudio, por ejemplo, e_1 en dicha figura es representada por la ecuación (3.31). El algoritmo propuesto en [21] retorna como resultado dos MTES, uno para cada falla mostrado después de la ecuación (3.32). Dichos MTES cumplen con la *definición 11*, ya que son los sub-conjuntos mínimos de ecuaciones donde la relación analítica es sensible a cada caso de falla considerada: Además, cumplen con la *definición 3*, tal que cada falla es sensible al menos a un residuo, como se muestra en las ecuaciones (3.32) y (3.33).

$$\dot{x}_1 = w_{gc} - w_{iv} \quad (3.36)$$

$$MTES_1 = [1, 4, 5, 10, 11, 12, 13, 14, 16, 17, 18, 20, 21, 23, 24]$$

$$MTES_2 = [1, 2, 5, 6, 7, 10, 11, 12, 13, 14, 16, 17, 18, 19, 23, 24]$$

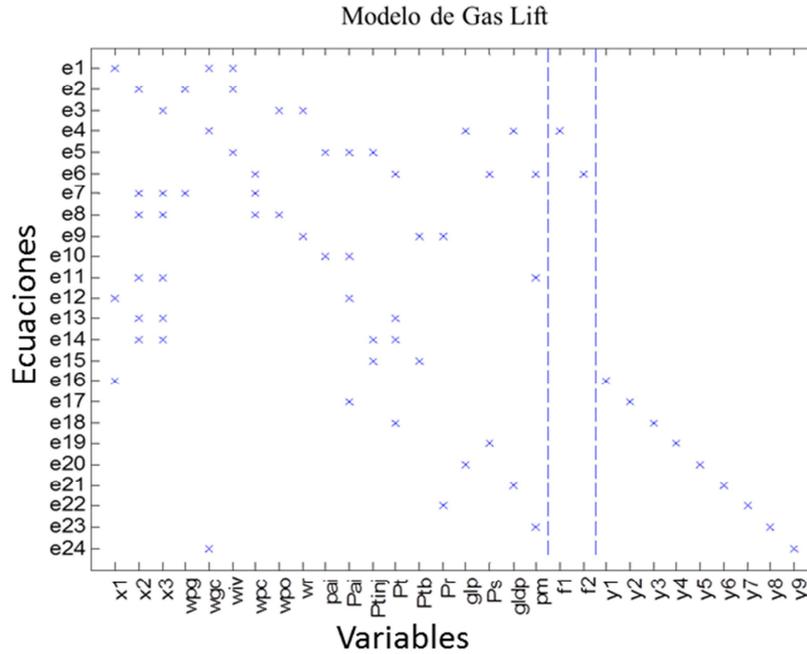


Figura 3.4- Matriz Incidencia con 2 fallas.

Las variables desconocidas en cada subconjunto del modelo pueden ser calculadas mediante la resolución del subconjunto de ecuaciones definidas en los MTES arrojados como resultados del algoritmo [21]. Para el caso de la Figura 3.4, se obtienen los residuos:

$$ARR_1 = x_1 + c_{iv} \sqrt{\frac{M}{RT_a}} \cdot P_a (P_a + gL_t P_m) - w_{gc} \quad (3.37)$$

$$ARR_2 = -\frac{\left[\frac{d}{dt}(x_2) - (w_{gc} - x_1)\right] \cdot (P_m L_t A_t + L_r A_r \rho_o)}{x_2} - c_{pc} \sqrt{P_m (P_t - P_s)} \quad (3.38)$$

Donde

$$x_2 = \frac{((1 - P_m V_o) L_t A_t + (1 - V_o \rho_o) L_r A_r)}{RT_t - MV_o P_t} \quad (3.39)$$

Para cumplir con la diagnosticabilidad, la *definición 4* sobre aislabilidad debe ser alcanzada. Cada firma de falla y los residuos deben ser diferentes entre sí. Es la importancia de la presente propuesta para alcanzar la diagnosticabilidad en este caso de estudio, en que sólo se utilizaron las variables de superficie del pozo, sin la necesidad de colocar sensores en la parte inferior, que son muy costosos y altamente sensibles a los daños.

En resumen, se ha utilizado una generación residual secuencial para obtener ARR desde los MTES propuestos en [53], tal que las variables desconocidas en el MTES se calculan de una en una, en secuencia, hasta obtener los ARR. Además, cada MTES es sensible a una falla, como se muestra en la Tabla 3.11.

Tabla 3.11- Matriz de firma de fallas con 2 fallas.

	N	f_1	f_2
Arr_1	0	1	0
Arr_2	0	0	1

Por otra parte, se ha probado el comportamiento del sistema cuando se produce las fallas y en estado normal (ver de la Figura 3.5 a la Figura 3.6). La Figura 3.5 muestra el análisis de residuos en el estado normal del sistema; en tal sentido, se puede observar que el comportamiento de los ARR es casi cero. En la Figura 3.6 muestra el comportamiento de ARR_1 frente ARR_2 cuando se produce f_1 . La falla f_1 se introduce en el espacio de tiempo entre 19.000 y 23.000 segundos, la línea azul es la falla simulada presente en el sistema, mientras que la línea roja es el comportamiento de los residuos generados por dicha falla. Se puede observar, que ARR_1 se activa durante este intervalo de tiempo, y su comportamiento es similar a la falla. En cuanto a ARR_2 , este es casi cero durante todo el periodo, salvo en el momento que inicia la f_1 , debido a que se inicia un cambio en el sistema.

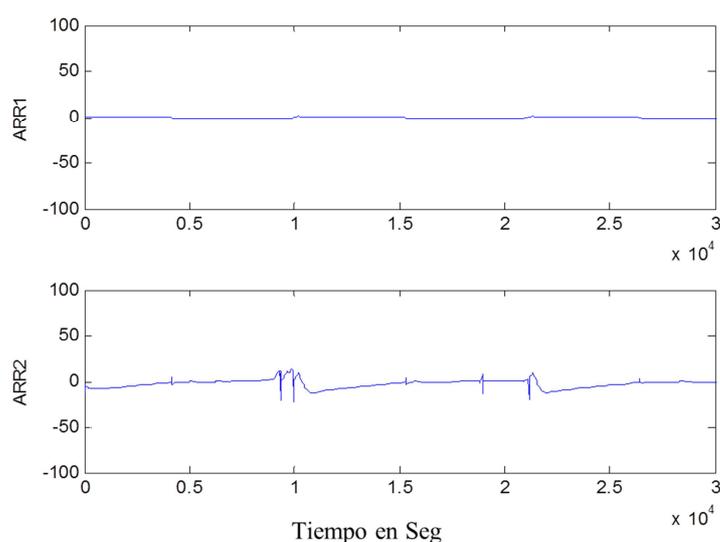


Figura 3.5 -Análisis de residuos en estado normal.

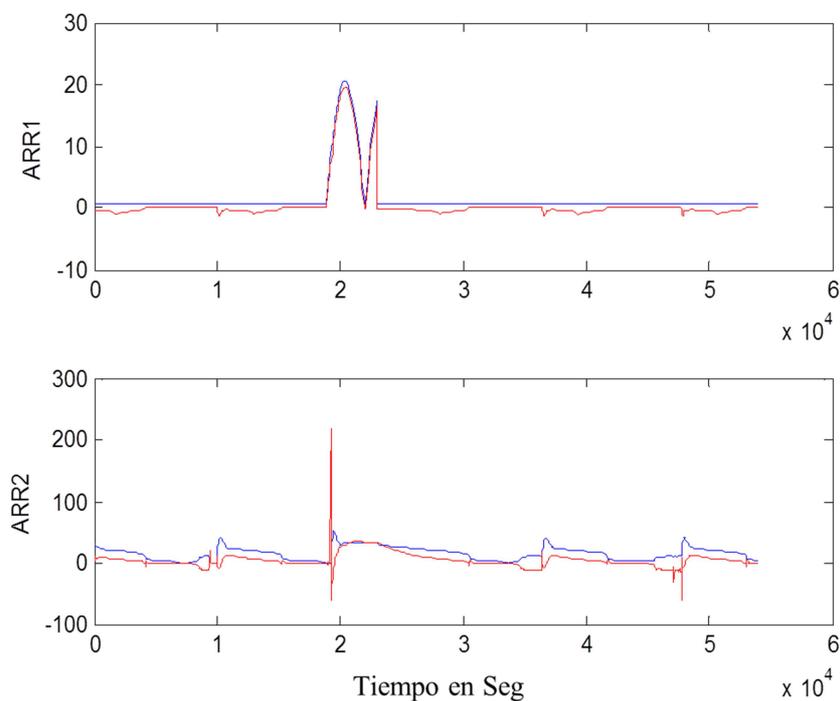


Figura 3.6- Análisis de residuos con f_1 activa.

Bajo este esquema, se simula ahora un mal funcionamiento en la salida del flujo mixto del sistema (f_2), para ver cómo se ven afectados los ARR en el intervalo de tiempo comprendido entre 5.000 a 10.000 segundos. La Figura 3.7 muestra ARR_1 frente ARR_2 cuando ocurre esta falla; ARR_2 se ve afectada, mientras que ARR_1 es cero.

Por último, se simula f_1 y f_2 juntas, esta vez activándolas en diferentes instantes de tiempo. f_1 se produce entre 7.000 y 12.000 segundos y f_2 se produce entre 22.000 y 27.000 segundos. En este caso, tanto ARR_1 y ARR_2 se ven afectados, en la Figura 3.8 se muestra el resultado. Los residuos se activaron en el instante en que ocurrieron las fallas a las cuales ellos son sensibles. De esta forma se distingue la propiedad de diagnosticabilidad.

Las definiciones que se abordan a lo largo del Capítulo 2 y Capítulo 3 sobre diagnosticabilidad, consideran que si hay una falla en el sistema debe estar asociado a uno o más ARR, y si se quiere discernir entre todas las fallas consideradas la firma de cada falla debe ser distinta. Particularmente, en el análisis realizado a un pozo LAG, los ARR

calculados logran la detección y el aislamiento de las fallas consideradas.

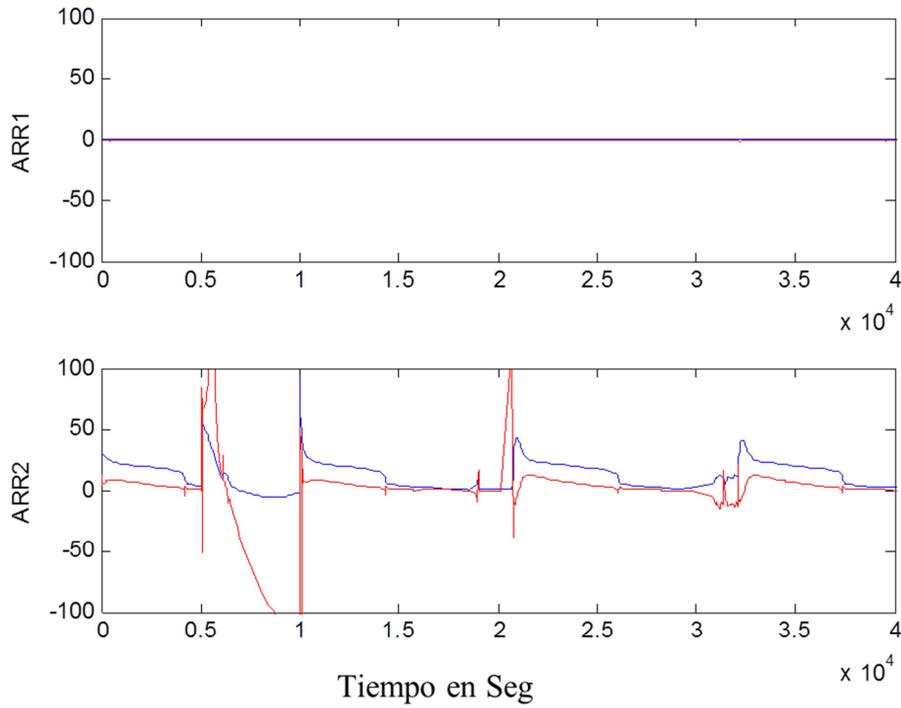


Figura 3.7- Análisis de residuos con f_2 activa.

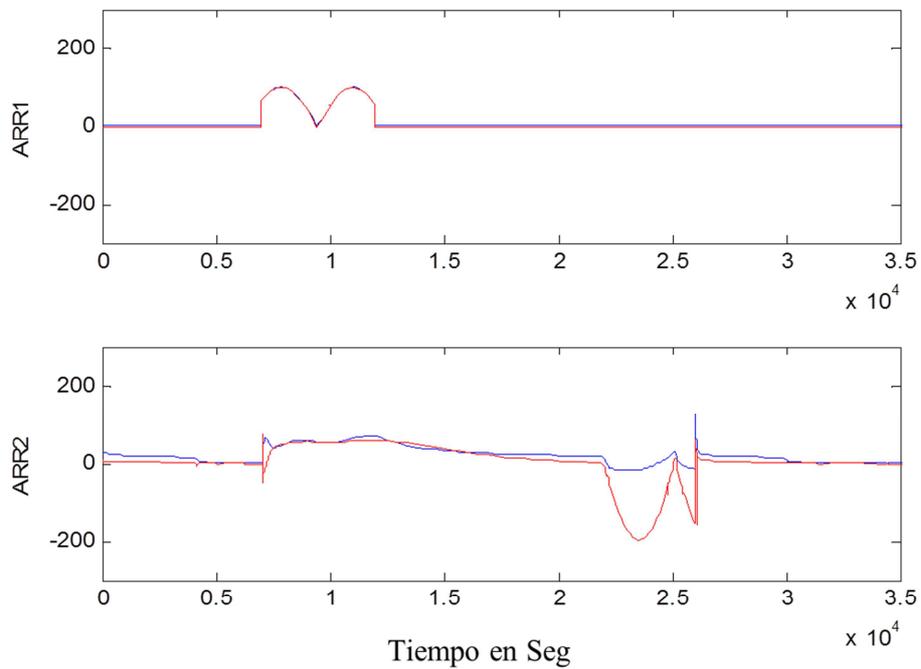


Figura 3.8- Análisis de residuos con f_1 y f_2 activas.

En resumen, en el presente caso de estudio se encontraron dos MTES, uno para cada falla considerada, además, el vector de esas fallas en la matriz de firma de fallas prueba que sus firmas son diferentes.

3.7.3. ANÁLISIS DE DIAGNOSTICABILIDAD EN UN POZO LAG CON CINCO FALLAS

A continuación, se procede a ampliar la solución a modelos donde se incrementa el número de fallas, para determinar si pueden ser estructuralmente detectables en el modelo original. En particular, se adicionan tres fallas a las dos consideradas en el estudio previo: f_3 (falla en el fluido mezclado en el tubing), f_4 (insuficiencia de presión en la parte inferior del tubing) y f_5 (falla en el tubing, en el punto de inyección de gas). El algoritmo propuesto en [21] genera la matriz de incidencia con cinco fallas mostrada en la Figura 3.9.

Además, el algoritmo propuesto en [21] también retorna la matriz de firma de fallas de la Tabla 3.12. Dicha tabla muestra que los únicos dos MTES generados no son satisfactorios para lograr una detectabilidad completa (no se detectan f_4 y f_5), y mucho menos la aislabilidad del proceso.

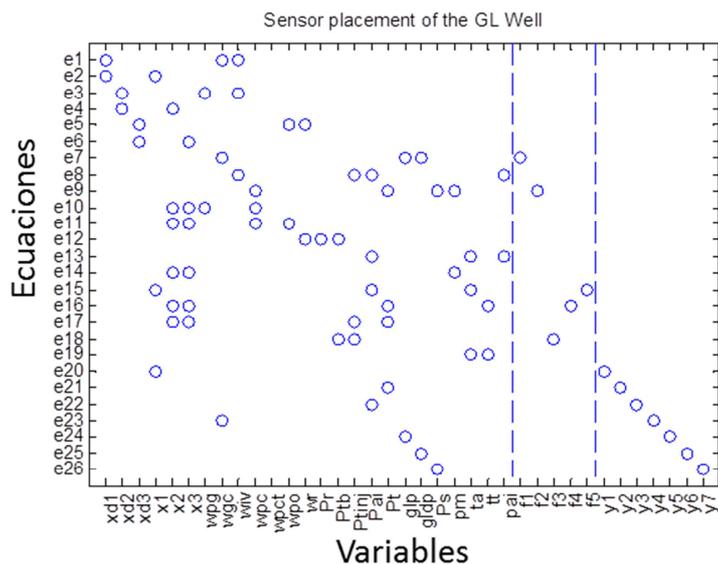


Figura 3.9- Matriz de incidencia para el análisis de cinco fallas.

Tabla 3.12- Matriz de firma de fallas para el análisis de cinco fallas.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	0	0	0	0
Arr_2	0	0	1	1	0	0

3.8. LOCALIZACIÓN DE SENSORES EN UN SISTEMA NO LINEAL

En esta sección se realiza un análisis de localización de sensores en un sistema no lineal, de manera de que se pueda distinguir la propiedad de diagnosticabilidad al incrementar su observabilidad. Se utiliza la técnica de localización de sensores propuesto en [7], enfoque basado en el análisis FDI y en ecuaciones de soporte de prueba. Se utilizará el ejemplo del sistema no lineal de la Sección 3.7.1, dado a que en el estudio anterior no fue posible aislar las fallas f_1 y f_2 .

3.8.1. LOCALIZACIÓN DE SENSORES BASADA EN TRABAJOS PREVIOS

La solución que se describe para el ejemplo descrito en la Sección 3.7.1, para las fallas en este modelo que no son aislables, consiste en encontrar el conjunto de sensores necesarios para obtener la aislabilidad de las fallas. Al correr el algoritmo propuesto en [7], se propone un sensor en x_1 para aislar f_1 de f_2 . La Figura 3.10 muestra la matriz de incidencia y la Tabla 3.13 la matriz de firmas de fallas. Además, el algoritmo propone la adición de una sexta falla, que es la falla en el propio sensor debido a que el sensor añadido puede fallar.

Siguiendo [7], la adición del sensor aumenta la redundancia para detectar las fallas consideradas. En la Tabla 3.13 se puede ver cómo se cumple detectabilidad, porque todos los ARR son sensibles al menos a una falla. También, todas las firmas son diferentes entre sí, lo que garantiza la aislabilidad de ellas. Así, se ha obtenido una nueva serie de MTES (ARR), capaz de alcanzar la propiedad diagnosticabilidad. Es decir, la localización de nuevos sensores aumenta la observabilidad en el sistema, con el fin de detectar y aislar más fallas.

Tabla 3.13- Matriz de firma de fallas para el análisis de las cinco fallas.

	N	f_1	f_2	f_3	f_4	f_5	f_6
Arr_1	0	0	0	0	1	1	0
Arr_2	0	0	0	1	0	1	0
Arr_3	0	0	0	1	1	0	0
Arr_4	0	0	1	0	1	0	1
Arr_5	0	0	1	0	0	1	1
Arr_6	0	0	1	1	0	0	1
Arr_7	0	1	0	0	0	0	1
Arr_8	0	1	1	0	0	1	0
Arr_9	0	1	1	0	1	0	0
Arr_{10}	0	1	1	1	0	0	0

Ejemplo de Sistema no lineal

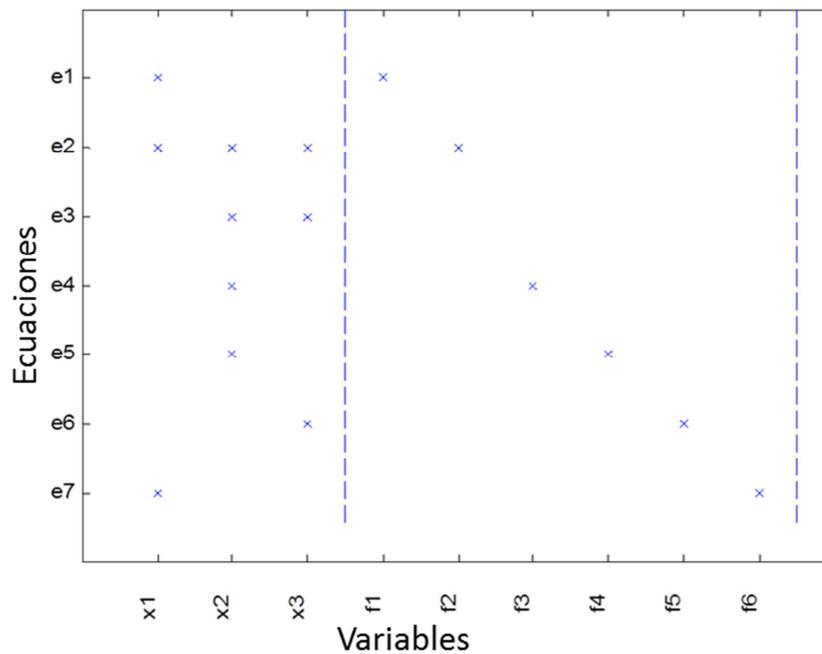


Figura 3.10 - Matriz de incidencia para el análisis de las cinco fallas

La dificultad para el análisis de diagnosticabilidad aumenta significativamente con el grado de complejidad de los sistemas, para la generación de residuos de calidad. Sobre todo, la selección satisfactoria de residuos a utilizar para la construcción de la MFF, que provea la información suficiente que permita determinar la detectabilidad y la aislabilidad de las fallas consideradas, esta situación puede tratarse como un problema combinatorio.

CAPÍTULO IV

MODELO INTELIGENTE PARA EL ANÁLISIS DE DIAGNOSTICABILIDAD

En este capítulo se presenta el modelo inteligente que resuelve el problema de optimización combinatoria de análisis estructural, el cual consiste en obtener el emparejamiento óptimo que describe la relación entre las ecuaciones y las variables del sistema. Además, resuelve el problema combinatorio de selección de residuos al momento de construir una MFF, garantizando que los sistemas tenga la propiedad de diagnosticabilidad. Finalmente, el modelo tiene la capacidad de analizar la posible localización de sensores si la propiedad de diagnosticabilidad no se cumple, incrementando la observabilidad, y con ello su redundancia. El modelo inteligente está basado en múltiples AG.

Por otro lado, en este capítulo se presentan los experimentos de análisis de diagnosticabilidad en procesos continuos utilizando el enfoque del modelo inteligente basado en AG expuesto a lo largo del presente capítulo. Eso nos permite comparar el enfoque inteligente con los trabajos [21, 27], en dos procesos continuos diferentes. Seguidamente se analiza el problema de localización de sensores con el modelo inteligente, por causa de la pérdida de la propiedad de diagnosticabilidad en el sistema, debido a la introducción de nuevas fallas o la eliminación de variables observadas en los procesos (se analiza el problema planteado en la Sección 3.7), para luego realizar la comparación con los resultados expuestos en el Capítulo 3.

4.1. ALGORITMOS PRINCIPALES DEL MODELO

Varios investigadores han implementado con éxito AG para el análisis de relaciones de redundancia de un sistema [4, 8, 9], además, existen enfoques donde se incluye el análisis en función a ecuaciones de soporte de prueba de manera de optimizar los resultados [21]. En esta investigación se trata de incorporar las características de optimización de los AG, para construir un modelo inteligente y cubrir todos los criterios de diagnosticabilidad fundamentados en el concepto de MSOS, con el fin de obtener un grado de redundancia igual a uno.

Definición 19: Modelo Inteligente de diagnóstico. Es el método utilizado para el análisis de diagnosticabilidad en un sistema, usando técnicas computacionales de la rama de la inteligencia artificial.

Para cumplir con lo anterior, se han desarrollado tres algoritmos, que durante sus ejecuciones invocan varios AG. El primer algoritmo llamado *Principal*, (ver Algoritmo 4.1), simplemente llama a los otros dos algoritmos (*Detección y Localización*).

El objetivo del algoritmo de detección es comprobar si se detectan y se aíslan todas las fallas consideradas en el estudio (ver las líneas 1-2, del algoritmo *Principal*). En la línea 2, si la propiedad de detectabilidad no se satisface ($MSOS(f) = \emptyset \forall f = 1, \#fallas$), o la propiedad de aislabilidad no es satisfecha ($ind_opt \neq \emptyset$, donde $ind_opt \neq \emptyset$ es una variable de control del segundo algoritmo), el tercer algoritmo (*Localización*) es invocado (ver línea 3), con el fin de asignar nuevos sensores a las variables desconocidas (incrementando así la redundancia del sistema).

Algoritmo 4.1. - Algoritmo Principal

Algoritmo 1 **Principal(G)**

```

1  MTES=Detección(G);
   % Determina la detectabilidad y la aislabilidad del sistema
2  si  $MSOS(f) = \emptyset \forall f = 1, \#fallas$  ó  $ind\_opt \neq \emptyset$ 
3    Localización (G);
   % Incremente la redundancia en el sistema para cumplir con la propiedad de
   % diagnosticabilidad, localizando sensores en variables desconocidas
4  fin
5  fin

```

El segundo algoritmo llamado *Detección*, (ver Algoritmo 4.2), busca los emparejamientos en el modelo estructural (un emparejamiento representa una relación de redundancia), basado en la teoría de MSOS. El algoritmo encuentra las posibles conexiones entre las variables y las ecuaciones, con el fin de obtener un subconjunto de ecuaciones que en un paso posterior permita eliminar las variables no observadas, y a su vez cumplir con los requisitos específicos de un ARR. En particular, se encuentran poblaciones de MSOS invocando el primer AG, llamado AG1. Este algoritmo también determina la detectabilidad y la aislabilidad (para el último caso utiliza un segundo AG, llamado AG2, que utiliza los mejores MSOS generados por AG1 para construir la matriz de firma de falla).

Algoritmo 4.2. - Algoritmo para Detección

```

Algoritmo 2 Detección ( $G$ )
1  repita para  $k = 1, k = \#fallas | f \in F$ 
   % Determina los MSOS para cada falla
2     $MSOS(f_k) = AG1(f_k, G)$ ;
3  fin
4  si al menos  $\exists MSOS(f) \neq \emptyset | \forall f \in F$ 
5    repita para  $i = 1, i = \#fallas | f \in F$ 
   % Determina el conjunto de fallas cubiertas por los MSOS de cada falla
6     $S(i) = det(i, MSOS(f_i))$ ;
7  fin
   % Determina la detectabilidad en el modelo
8  si  $verificacion(S) = verdad$ 
   % Construye la matriz de firma de fallas
9     $S_m = iso(f_i, S)$ ;
   % Determina la aislabilidad de las fallas ( $ind_{opt} = \emptyset$ )
10    $ind_{opt} = AG2(S_m)$ 
11 fin
12 fin

```

En la línea 2 del segundo algoritmo se hace la invocación al AG1, para determinar todos los MSOS posibles para cada falla. La línea 4 garantiza que al menos un MSOS se ha definido para cada falla. La llamada *det* en la línea 6, determina el conjunto de fallas cubierta por cada MSOS, y los incluye en S (la matriz de firma de falla). Con esta información, el algoritmo verifica en la línea 8 si todas las fallas están cubiertas, utilizando el procedimiento de *verificación*(S), y se determina la detectabilidad del modelo (si todas las fallas pueden ser detectadas). Luego, en la línea 9 se construye la matriz de firma de falla (para eso, se llama al procedimiento *iso*). Finalmente, en la línea 10 se determina la aislabilidad de las fallas usando la matriz de firma de fallas.

Con el fin de verificar la aislabilidad del sistema, se hace un llamado a un segundo AG en la línea 10 del Algoritmo 4.2, para construir la matriz de firma de fallas como parámetro. Si el sistema es aislable, el mejor individuo de AG2 cumple con el criterio de la propiedad de aislabilidad (en el análisis del sistema se puede distinguir la propiedad diagnosticabilidad), siendo la MFF del sistema. Si esta propiedad no se puede distinguir, entonces $ind_{opt} \neq \emptyset$, para invocar en el algoritmo principal al tercer algoritmo (algoritmo *Localización*), que se utiliza cuando hay fallas no detectadas o no aisladas (ver Algoritmo 4.3).

Algoritmo 4.3. - Algoritmo para la Localización de Sensores

Algoritmo 3 **Localización (G)**

% Propone sensores en variables desconocidas

```

1  cost = AG3(G, G', cost)
2  Detección (G')
3  si AG3 converge debido a Nb_generaciones entonces
4    imprimir "El Sistema no cumple con la Diagnosticabilidad"
5  sino
6    imprimir "El costo del sensor es" cost, "y la nueva configuración es" G'
7  fin

```

El algoritmo de *Localización* utiliza otro AG, llamado AG3, para generar un conjunto de posibles localizaciones de sensores (cada individuo es una posible combinación de localización de un sensor o sensores en variables desconocidas) con respecto a las fallas consideradas a detectar o aislar, además, se incorpora el costo de la implantación de los sensores, con el fin de elegir el valor más bajo, para economizarlos costos en el momento de la implantación (ver línea 6).

El nuevo grafo bipartito propuesto por AG3 que representa el modelo estructural del sistema es G' , posteriormente, es evaluado en el algoritmo *Detección*, como se muestra en la línea 2. Según las líneas 3 y 5, si AG3 converge debido a la cantidad de generación, entonces significa que no hay individuos (G') que cumplan con la propiedad de diagnosticabilidad (véase la siguiente sección, donde se explica AG3), es decir, es una propiedad que no puede alcanzar el sistema real (véase la línea 4). De lo contrario, el individuo G' es el nuevo grafo bipartito del sistema, y la localización de los nuevos sensores tiene un costo de acuerdo a la función de aptitud del individuo (línea 6).

4.2. ALGORITMOS GENÉTICOS USADOS PARA EL ANÁLISIS DE DIAGNOSTICABILIDAD

En las secciones siguientes se procede a describir los tres AGs usados en el enfoque propuesto en la presente investigación. Un AG1 con una función de evaluación multi-objetivo, en donde determinan los MSOS según la falla en estudio, y con ella su detectabilidad; un AG2 que construye una MFF en aras de comparar el efecto que tiene cada MSOS en el conjunto de fallas, y con ello en la aislabilidad del sistema; y por último, en caso de no obtenerse la propiedad de diagnosticabilidad se propone un tercer AG3 que realiza modificaciones en el sistema, en particular la localización de nuevos sensores, para incrementar la observabilidad del sistema.

4.2.1. AG1 PARA ENCONTRAR POBLACIÓN DE MSOS

Dado un modelo M , su propiedad de diagnosticabilidad puede ser analizada utilizando un modelo estructural del sistema como grafo bipartito G (por ejemplo, la Figura 4.1 muestra un grafo bipartito del sistema de ecuaciones detallado en la sección 3.7.1). Para este caso, en la Figura 4.2. se muestra la estructura general del individuo que lo representa en AG1, el cual es representado por los posibles arcos entre la unión del conjunto de las fallas y el conjunto de las variables desconocidas $G = G_X \cup G_F$, donde de G_F se extrae la falla a estudiar f_k y el conjunto de ecuaciones E . AG1 genera una población inicial de cincuenta individuos con combinaciones aleatorias de arcos activos en el modelo con esa falla (un arco activo es cuando se selecciona la relación entre una ecuación y una variable para componer los posibles MSOS definidos por este individuo de la falla f_k , ver adelante para más detalles). Es decir, cada individuo va a definir un posible MSOS. La función objetivo permite determinar la propiedad de detectabilidad de los posibles MSOS, y los mejores individuos serán la entrada del AG2, con el fin de estudiar la propiedad de aislabilidad.

Un individuo “C” en AG1 es representado por una cadena de bits, donde el tamaño del individuo es el producto de la multiplicación de la cantidad de ecuaciones por la cantidad de variables desconocidas (G_X) y de fallas consideradas (G_F), y cada bit representa los posibles arcos que conectan los vértices en el grafo bipartito, tal que para cada a_{ij} o a_{kj} , a

es el arco entre el vértice i (representa la variable desconocida $x_i, \forall i=1$ número de variables desconocidas) o k (representa la falla $f_q, \forall q=1$, número de fallas), en la parte superior del grafo bipartito, con j (representa la ecuación $e_p, \forall p=1$, número de ecuaciones), en la parte inferior del grafo bipartito (ver Figuras 4.1 y 4.2). Si se selecciona un arco, entonces el valor de a_{ij} o $a_{kj} = 1$ (arco activo), de lo contrario, a_{ij} o $a_{kj} = 0$ (representa que este arco no existe en el grafo bipartito, o es un arco que no está activo) ver Figura 4.2. Para el caso del grafo bipartito de la Figura 4.1, un posible ejemplo de un individuo “CI” es mostrado en la Figura 4.3, donde las líneas de color rojo representan los arcos activos en CI y la cadena de bit que representa al individuo es mostrada en la Tabla 4.1.

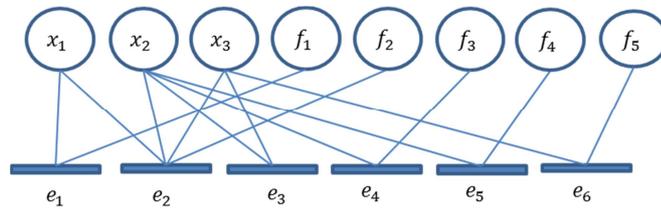


Figura 4.1 - Ejemplo de un Grafo bipartito.

110000011110011001100000010000000100000010000001

a_{13} es la representación de la relación entre del vertice superior de G (x_i o f_k) y el vertice inferior e_j no seleccionada o no existente en el individuo

a_{11} es la representación de la relación entre del vertice superior de G (x_i o f_k) y el vertice inferior e_j seleccionada en el individuo

Figura 4.2- Estructura del modelo en AG1 para la Figura 4.1.

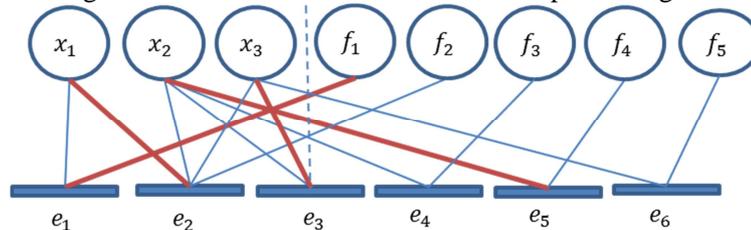


Figura 4.3 - Posible individuo C1 para AG1.

Tabla 4.1 - Representación del individuo de la Figura 4.3.

G	
G_X	[0,1,0,0,0,0;0,0,0,0,1,0;0,0,1,0,0,0];
G_F	[1,0,0,0,0;0,0,0,0,0;0,0,0,0,0;0,0,0,0,0;0,0,0,0,0;0,0,0,0,0];

Por lo tanto, para cada individuo que es un posible MSOS para la falla f_k , existe una secuencia única de cadena de bits. El MSOS (individuo) se evalúa utilizando la función multi-objetivo que incluye todos los criterios de diseño importantes de un MSOS ver (4.1), garantizando la detectabilidad de la falla considerada, de un grado de redundancia igual a 1. El algoritmo general AG1 es mostrado en el Algoritmo 4.4.

Algoritmo 4.4. - Algoritmo Genético 1.

```

Algoritmo Genético 1( $f_k$  G)
1  Inicio AG1
   % Genera la población inicial
2  Pop(C)=genera_pop(G);
   % Calcula el valor de la función objetivo en cada individuo
3  Evaluación( $FF_1$ ,pop);
4  repita mientras no  $FF_1 = \emptyset$  o Nb_generaciones hacer
5     inicio
   % Inicia ciclo reproductivo
6     Reproducción (pop)
7     Evaluación ( $FF_1$ , pop)
8     Selección (pop)
9     fin
10  fin
11 fin

```

La línea 2 genera la población inicial de cincuenta individuos de manera aleatoria, basados en el modelo original del sistema de manera que sea consistente con el mismo, y la línea 3 evalúa esta población utilizando la función de aptitud FF_1 que se describe más adelante. Luego, entre las líneas 4 y 11 hay un proceso evolutivo clásico, donde luego de la evaluación FF_1 los dos mejores individuos son seleccionados como padres para aplicarles el operador de cruce, posteriormente se aplica el operador de mutación como mecanismos de reproducción, continuando con el ciclo de evaluación y de selección de los individuos. Este proceso evolutivo se detiene cuando se alcanza un número de veinte generaciones sin ningún tipo de evolución alguna, o cuando un individuo llega a un valor de $FF_1 = 0$ (este MSOS representa un residuo de la falla f_k).

FF_1 es una función multi-objetivo representada en (4.1), que permite encontrar MSOS para la falla f_k . El enfoque es de una suma ponderada, utilizado para agregar todos los criterios de optimización seleccionados. El mínimo valor numérico de FF_1 determina la

calidad de cada solución posible (MSOS), el cual permite minimizar las ecuaciones involucradas en la redundancia seleccionada y llegar eventualmente a $\varphi(\mathcal{M}) = 1$.

$$FF_1 = \text{Min} \left\{ \sum_{n=1}^3 w_n P_n \right\} \quad (4.1)$$

Donde, w_n es el peso correspondiente de cada criterio y P_n es el criterio de evaluación a ser optimizado. Los diferentes criterios de diseño a ser optimizados se muestran en la Tabla 4.2, y FF_1 en general es de la forma mostrada en (4.2).

Tabla 4.2 - Criterio de la Optimización.

Objetivo	Criterio de Optimización
P_1	Numero de fallas
P_2	Falla en estudio
P_3	Cardinalidad del sistema

$$FF_1 = w_1 P_1 + w_2 P_2 + w_3 P_3 \quad (4.2)$$

En esta función objetivo la importancia de cada criterio se define por el peso w_n ($n = 1, 2, 3$). Los valores se determinan de acuerdo con los requisitos de diseño y experimentación (véase la Tabla 4.3). El peso con mayor valor es w_3 , que determina la redundancia del sistema, que es el criterio más importante a optimizar ya que sin la redundancia no sería posible la detección de falla; además, es este criterio el que posibilita establecer que $\varphi(\mathcal{M}) = 1$. El peso w_2 determina que la falla analizada sea la que se quiere estudiar f_k , ya que se debe tener en cuenta para determinar la redundancia en función de ella, eliminando cualquier individuo que no contenga un arco activo entre las ecuaciones y la falla en estudio. Por último una relación de redundancia o el MSOS puede ser sensible a varias fallas al mismo tiempo, por tal motivo w_1 es el de menor peso, ya que el criterio de aislabilidad será evaluado en el AG2.

Tabla 4.3 - Coeficiente de los pesos.

Objetivo	Criterio	Valor de Optimización
w_1	Numero de Fallas	100
w_2	Falla en estudio	1000
w_3	Redundancia del sistema	10000

Particularmente, en AG1 los individuos élite (los individuos con los mejores valores de aptitud) de cada generación se eligen, con el fin de asegurar que los mejores individuos actuales siempre sobreviven en la próxima generación. Bajo esta consideración, los valores de optimización fueron seleccionados de manera que no se puedan permitir resultados de individuos con valores más alto de 10000, ya que no existiría redundancia en el sistema, ni mayor a 1000, ya que no estaría seleccionada la falla en estudio en el individuo. Sin embargo, los individuos con valores en múltiplos de 100 no mayores a 1000 pueden ser seleccionados, porque pueden ser seleccionados como entradas del AG2, donde se evaluará la propiedad de aislabilidad, y de no obtenerse los resultados deseados invocar al Algoritmo de *Localización*.

El primer criterio que se describe es el P_1 , el cual evalúa la cantidad de fallas sensibles al MSOS evaluado, donde lo ideal es que sea sólo la falla en estudio f_k en un momento específico (o la menor cantidad de fallas). Se describe por la suma de los arcos activos desde las fallas que se encuentran en la parte G_F del individuo diferentes a f_k , (la falla en estudio). Si esta cantidad es diferente de cero, entonces se penaliza la ecuación con un peso w_1 .

$$P_1 = \sum_{\substack{f_i \in F \\ f_i \neq f_k}} \sum_{j=1}^m a_{kj} \quad (4.3)$$

Donde

a_{kj} son los arcos activos en el individuo entre los vértices de las fallas y de las ecuaciones

f_k falla en estudio
 m número de ecuaciones

La evaluación de P_1 en el individuo representado en la Figura 4.3 (C1), es mostrado en (4.4), donde el valor que arroja es cero, por tener un solo arco activo en el conjunto que pertenece a G_F .

$$P_1 = 0 \quad (4.4)$$

El criterio P_2 denotada en (4.5) asegura que la falla en estudio f_k este considerada por el individuo: se hará una suma de los arcos activos de la falla estudiada presentes en el

individuo. Normalmente debe existir sólo un arco activo de la falla estudiada para garantizar un MSOS, de lo contrario este valor es distinto de cero, y el individuo debe ser penalizado con un peso w_2 .

$$P_2 = \left| \sum_{j=1}^m a_{f_k j} - 1 \right| \quad (4.5)$$

Donde

$a_{f_k j}$ son los arcos activos en el individuo entre la fallas en estudio y las ecuaciones.

La evaluación de P_2 en el individuo representado en la Figura 4.3 (C1), es mostrada en (4.6), y verifica que solo se encuentre activo un arco desde la falla considerada en el estudio (f_l).

$$P_2 = |1 - 1| = 0 \quad (4.6)$$

El criterio P_3 denotada en (4.7) verifica que el grado de redundancia del modelo sea igual a uno $\varphi(\mathcal{M}) = 1$, es decir, hay una ecuación más que variables desconocidas. Para ello, comprueba que la diferencia de la cardinalidad de las ecuaciones j menos la cardinalidad de las variables x del individuo "C" que están enlazadas por los arcos activos en el individuo sea uno, para garantizar la propiedad que caracteriza a un MSOS. El valor absoluto de esta función debe arrojar como resultado el valor de cero, de lo contrario el individuo debe ser penalizado con un peso w_3 .

$$P_3 = \left| (Card(J^*) - Card(I^*)) - 1 \right|_{\substack{I^* = \{i | \exists a_{ij} = 1 \vee j = 1, m\} \\ J^* = \{j | \exists a_{ij} = 1 \vee i = 1, n\}}} \quad (4.7)$$

donde

I^* son los arcos activos de las variables desconocidas que pertenecen a J^*
 J^* son los arcos activos en el conjunto de las ecuaciones

La ecuación (4.8) muestra la evaluación de P_3 en el individuo CI , ella verifica sí la redundancia en el individuo es igual a uno. Para el caso concreto de CI , existen 3 variables y 4 ecuaciones seleccionadas.

$$P_3 = |(4 - 3) - 1| = 0 \quad (4.8)$$

Finalmente, en (4.9) evaluamos a CI con FF_1 , dando;

$$FF_1 = 100(0) + 1000(0) + 10000(0) = 0 \quad (4.9)$$

A continuación definimos un Lema que sustenta la definición del criterio de la ecuación FF_1 .

Lema 1. Sea un sistema M , si en el análisis se obtiene un individuo cuya evaluación $FF_1=0$, existe un sub modelos del sistema \mathcal{M} que representa un MSOS sensible a una falla considerada f_k , tal que su grado de redundancia es $\varphi(\mathcal{M}) = 1$. AG1 debe obtener tantos individuos hasta cubrir todas las fallas consideradas.

Prueba del Lema 1: el conjunto \mathcal{M} es una familia de ecuaciones que describen el comportamiento del sistema en SO. A partir de ese conjunto, se pueden obtener los MSOS necesarios para detectar y aislar las fallas consideradas, con los cuales se construye la MFF. $FF_1 = 0$ asegura un MSOS para una falla en estudio f_k (determinado por P_1 y P_2), y el conjunto de individuos con $FF_1 = 0$ será el conjunto de MSOS de la fallas consideradas (cubren todas las fallas en estudio), donde P_3 asegura que cada uno sea $\varphi(\mathcal{M}) = 1$. De esta manera, cada FF_1 asegura la sensibilidad a una falla considerada.

Posterior a la evaluación de FF_1 el mecanismo de reproducción es el clásico usado en los AG. En primera instancia se seleccionan como padres los dos mejores individuos de la población evaluada, posteriormente se realiza un mecanismo de cruce con un coeficiente de probabilidad de 0.7 para luego utilizar un mecanismo de mutación con un coeficiente de probabilidad de 0.9.

4.2.2. AG2 PARA EL ANÁLISIS DE DETECTABILIDAD Y AISLABILIDAD

La población resultante de AG1 implica tal vez un gran número de MSOS. Dado a que existe una relación uno a uno entre los ARRs y MSOSs, y si la propiedad de detectabilidad se alcanza en el sistema, la línea 10 del algoritmo de *Detección* construye la

matriz de firmas de fallas y llama Algoritmo 4.5 llamado AG2, con el fin de determinar un conjunto de ARRs que garantice la propiedades de detectabilidad y de aislabilidad del sistema.

Algoritmo 4.5. - Algoritmo Genético 2.

```

Algoritmo Genético 2 ( $S_m$ )
1  Inicio GA2
2    pop=genera_pop( $S_m$ );
   % Genera la población inicial con los Arr de  $S_m$ 
3  Evaluación( $FF_2$ , pop);
   % Calcula la función objetivo de cada individuo
4  mientras  $FF_2 \neq \emptyset$  or Nb_generaciones hacer
5    inicio
   % comienza el ciclo de reproducción
6      Nueva Reproducción(pop)
7      Evaluación ( $FF_2$ , pop)
8      selección (pop)
9    fin
10 fin
11 fin

```

El individuo en AG2 también está representado por una cadena de bits. En este caso, cada bit representa cada MSOS (ARR) encontrado por AG1 para todas las fallas (Tabla 4.4 muestra un ejemplo de los MSOS obtenidos por AG1). AG2 define aleatoriamente individuos para ser posteriormente evaluadas por la función objetivo, donde un bit con el valor de uno "1" significa que ese MSOS se elige para conformar la matriz de firmas de fallas, de otro modo su valor es cero "0" (Figura 4.4 representa un posible individuo, para el ejemplo de la Tabla 4.4). AG2 estudia la sensibilidad de las fallas en cada MSOS seleccionado en un individuo, y observa si en ese individuo se cumplen las propiedades de detectabilidad y de aislabilidad o no.

Tabla 4.4 -Población de posibles MSOS para la Figura 41.

POBLACIÓN DE LOS POSIBLES MSOS OBTENIDOS POR EL AG1	
MSOS	[3 5 6]
	[3 4 6]
	[4 5]
	[1 2 3 6]
	[1 2 3 5]
	[1 2 3 4]

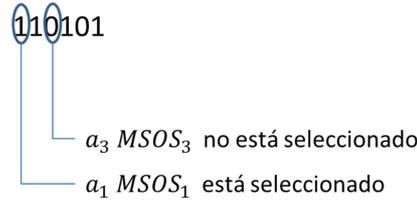


Figura 4.4- Estructura de un individuo del AG2, para el ejemplo de la Figura 3.1.

La función objetivo de AG2 asegura que su valor es cero cuando el individuo tiene la propiedad de diagnosticabilidad. De lo contrario, este individuo no puede aislar las fallas (no cumple la propiedad de aislabilidad). Se eligió el criterio de tener como población una cantidad de veinte individuos, ya que en esta ocasión el objetivo principal es hallar una selección de las posibles combinaciones de los mejores resultados generados en el AG1.

Hay dos condiciones en la función objetivo mostrado en (4.10). La primera condición O^1 (ver la ecuación (4.11)) asegura que el vector columna de firma de la falla f_i , donde $i=\{1, \dots, \ell\}$ y ℓ es el número de fallas estudiadas (construida para el individuo en evaluación), es linealmente independiente al resto de vectores columnas f , o a las combinaciones lineales que se derivan de esos vectores f , de lo contrario se penaliza con un valor bajo. O^2 (ver ecuación (4.12)) es la condición que garantiza que la suma de cada vector columna en la matriz de firmas de fallas es distinto de cero, de lo contrario no puede distinguirse el comportamiento de un sistema con falla de un comportamiento normal, penalizando el individuo con un valor alto.

$$FF_2 = \sum_{i=1}^{\ell} \sum_{k=1}^{2n-1} O_{ik}^1 + \sum_{i=1}^{\ell} O_i^2 \quad (4.10)$$

Donde O_{ik}^1 y O_i^2 son;

$$O_{ik}^1 = \begin{cases} \emptyset, & \text{si } C_i \neq C_k(M'_k(i)) \\ 10, & \text{de lo contrario} \end{cases} \quad (4.11)$$

$$O_i^2 = \begin{cases} \emptyset & \text{si } \sum_{k=1}^{\#ARRS} C_{i_k} \neq \emptyset \\ 10000 & \text{de lo contrario} \end{cases} \quad (4.12)$$

Donde $M'_k(i)$ es la matriz de las posibles combinaciones de los vectores columnas del resto de fallas C_k de la MFF diferentes a f_i , que se comparan con el vector columna C_i de

la falla (C_i es equivalente a S_i , definido en (2.6)), con $2^n - 1$ columnas, que son las posibles combinaciones de las columnas de la MFF sin la falla f_i . Cada columna $M'_k(i)$ se calcula de la siguiente manera:

$$M'_k(i) = \bigcup_{j=1}^{\ell-1} MS_j(i) \times cond \quad \forall k = 1, 2^n - 1 \quad (4.13)$$

Donde $MS(i)$ es la MFF sin la falla f_i , y $cond$ es igual a:

$$cond = \begin{cases} [0] & \text{si } Mcomb_{kj}(i) = 0 \\ [1] & \text{de lo contrario} \end{cases} \quad (4.14)$$

$Mcomb_{kj}(i)$ contiene todas las posibles combinaciones de la columnas de la MFF sin incluir la falla f_i , de dimensión $(2^n - 1) \times (\ell - 1)$, y $cond$ significa un vector de solo 1s o 0s. Un ejemplo de la matriz $MS(1)$ para analizar la falla f_1 es mostrado en la Tabla 4.5, y de $Mcomb(1)$, se muestra en la Tabla 4.6, para el caso del *Ejemplo 3*, el cual se ha estudiado a lo largo de este trabajo:

Tabla 4.5 - $MS(1)$, MFF sin la falla f_1

	f_2	f_3	f_4	f_5
Arr_1	1	0	0	1
Arr_2	1	0	1	0
Arr_3	0	0	1	1
Arr_4	1	1	0	0
Arr_5	0	1	1	0
Arr_6	0	1	0	1

Tabla 4.6 – Posibles combinaciones ($Mcomb(1)$), para la comparación con la falla f_1

	f_2	f_3	f_4	f_5
1	0	0	0	0
0	1	0	0	0
1	1	0	0	0
0	0	1	0	0
1	0	1	0	0
0	1	1	0	0
1	1	1	0	0
0	0	0	1	0
1	0	0	1	0
0	1	0	1	0
1	1	0	1	0
0	0	1	1	0
1	0	1	1	0
0	1	1	1	0
1	1	1	1	0

Y el cálculo de la matriz $M'_k(1)$, resultado de la ecuación (4.13), es mostrado en la Tabla 4.7. Esa matriz presenta las uniones de las fallas restantes $\{2, \dots, 5\}$, es decir que f_{23} es la unión de la falla $f_2 \cup f_3$, y así sucesivamente, hasta obtener todas las combinaciones posibles, en concordancia con el *Ejemplo 3*.

Tabla 4.7 - $M'_k(1)$ combinaciones de las f_k fallas de MFF sin la f_1

	f_2	f_3	f_4	f_5	f_{23}	f_{24}	f_{25}	f_{34}	f_{35}	f_{45}	f_{234}	f_{235}	f_{245}	f_{345}	f_{2345}
<i>Arr</i> ₁	1	0	0	1	1	1	1	0	1	1	1	1	1	1	1
<i>Arr</i> ₂	1	0	1	0	1	1	1	1	0	1	1	1	1	1	1
<i>Arr</i> ₃	0	0	1	1	0	1	1	1	1	1	1	1	1	1	1
<i>Arr</i> ₄	1	1	0	0	1	1	1	1	1	0	1	1	1	1	1
<i>Arr</i> ₅	0	1	1	0	1	1	0	1	1	1	1	1	1	1	1
<i>Arr</i> ₆	0	1	0	1	1	0	1	1	1	1	1	1	1	1	1

La matriz $M'_k(1)$ garantiza poder determinar la no linealidad entre las fallas en el sistema.

La Tabla 4.8 muestra tres posibles individuos de la Tabla 4.4, los cuales son evaluados en la Tabla 4.9 para la condición O^1 , y en la Tabla 4.10 para la condición de O^2 .

Tabla 4.8- Población de posibles individuos para el ejemplo de la Tabla 4.4.

INDIVIDUOS DEL AG2	
A_1	[011100]
A_2	[111111]
A_3	[001011]

Tabla 4.9- Evaluación de O^1 para los individuos de la Tabla 4.8.

O^1		f_1, f_2	f_1, f_3	...	f_2, f_3	...	$f_1, f_2 \cup f_3$...	$f_1, f_2 \cup f_3 \cup f_4 \cup f_5$...	f_4, f_5
1	A_1	10	10	...	0	...	0	...	0	...	10
2	A_2	10	0	...	0	...	0	...	0	...	0
3	A_3	10	0	...	0	...	0	...	0	...	0

Tabla 4.10- Evaluación de O^2 para los individuos de la Tabla 4.8.

O^2		f_1	f_2	f_3	f_4	f_5
1	A_1	0	0	0	0	0
2	A_2	0	0	0	0	0
3	A_3	10000	10000	0	0	0

Esos valores son calculados a partir de las firmas de falla que se generan con cada individuo. Por ejemplo, para A_2 , la Tabla 4.11 muestra su MFF.

Tabla 4.11 -Matriz de firma de falla para A_2 .

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	0	0	1
Arr_2	0	1	1	0	1	0
Arr_3	0	0	0	0	1	1
Arr_4	0	1	1	1	0	0
Arr_5	0	0	0	1	1	0
Arr_6	0	0	0	1	0	1

Este AG genera los individuos iniciales usando S_m (la matriz de firmas de fallas), y el resto del procedimiento es una AG clásico. Un valor diferente de cero en la condición O_{ik}^1 de un individuo significa que al menos una falla no es aislable entre el conjunto de fallas, para lo cual se eligió un valor de peso bajo (10), de manera que se pueda invocar al Algoritmo de *Localización*. Ahora bien, si no logra detectar alguna de las fallas en estudio (es decir, la suma del vector de la firma es igual a 1, ver condición O_i^2), el individuo es penalizado con un alto valor (10000), para indicar que no es una posible solución.

La línea 2 del algoritmo 4.5 genera la población inicial con la matriz de firma de fallas (S_m), después es un AG clásico que utiliza durante su evolución la función de aptitud FF_2 .

Por ejemplo, para el individuo A_2 de la Tabla 4.9, su valor para la condición de O^1 es 10 debido a que f_1 y f_2 no pueden ser aisladas una de la otra en el sistema (ver Tabla 4.9). Por otro lado, su valor en la condición O^2 es 0, ya que todas las fallas consideradas son diferentes al modo normal (ver Tabla 4.10). Así que, el valor del individuo es $FF_2=10$, ubicando al individuo en el rango $0 < FF_2 < 10000$, es decir detecta pero no aísla todas las fallas.

Lema 2: Sea un conjunto de individuos provenientes de AG1, si existe en el análisis de AG2 un individuo con valor $FF_2 = 0$, se concluye que él mismo es una MFF que cumple con las propiedades de aislabilidad y detectabilidad.

Prueba del Lema 2: Los individuos en el AG2 con valor $FF_2 = 0$ cumplen la propiedad de diagnosticabilidad, ya que $O^1 = 0$ asegura que todas las fallas se pueden aislar (tienen ARR's diferentes) y $O^2 = 0$ asegura que todas las fallas se pueden detectar ($\forall f_k \in F, f_n(\mathcal{M}) \neq f_k(\mathcal{M})$ donde $f_n(\mathcal{M})$ es el modo normal). Un individuo con $0 < FF_2 < 10000$ representa que al menos una falla no es aislable de otra en las condiciones actuales ($\exists_{f_i, f_j \in F} f_i(M) = f_j(M)$) (ver todos los individuos en la Tabla 3.6 y la ecuación (4.11); y un individuo con $FF_2 > 10000$ (ver la ecuación (4.12)) no es una posible solución, ya que el individuo no detecta alguna falla ($\exists_{f_k \in F} f_k(M) = 0$) en la MFF (ver A_3 en la Tabla 4.10). De esta manera se cumple con los Teoremas 1 y 2.

4.3. AG3 PARA LOCALIZACIÓN DE SENSORES

En el caso de que en el análisis de diagnosticabilidad del sistema no se pueda determinar las propiedades de detectabilidad o aislabilidad, en el algoritmo 3 (*Localización*) se realiza la invocación a un nuevo AG, llamado AG3, el cual propone un nuevo grafo bipartito G' [54, 55]. Para ello, se seleccionan aleatoriamente variables desconocidas, y AG3 las asume como variables conocidas del sistema, lo cual involucra incorporar sensores en el sistema para que puedan ser conocidas (se puedan medir).

En AG3, los grafos G' se generan aleatoriamente desde G (cada G' es un individuo, ver la línea 3 del algoritmo 4.6), al incluirse nuevos arcos como activos.

El Algoritmo 4.6 revisa si con esa nueva configuración de sensores propuesta por cada individuo, se cumple con las propiedades de detectabilidad y aislabilidad (para eso, AG3 invoca el algoritmo *Detección* con G' como parámetro, ver la línea 6). Mientras no se consigan individuos que cumplan con esas propiedades se generan nuevos G' (individuos), durante un determinado número de generaciones (ver líneas 6 al 9). Si AG3 logra varios individuos con esta propiedad, a continuación elige al individuo con el menor costo de implementación de la nueva configuración de sensores (ver la línea 16), que se determina en función del costo de implantación de los sensores que se definen en cada individuo (ver la línea 14).

AG3 resuelve el problema de localización de sensores, y su resultado será el individuo con el menor costo para llegar a la propiedad diagnosticabilidad. Los individuos de AG3 son estructuralmente similares a los individuos de AG1, es decir, una cadena de bits. El algoritmo que genera aleatoriamente la población de individuos G' (lleva a cabo una variación de G), se muestra a continuación.

Algoritmo 4.6.- Algoritmo Genético 3.

```

Algoritmo Genético 3 ( $G, G', cost$ )
1  Inicio AG3
2  repita hasta tamaño de la población
3       $G' = generacion\_aleatorea(G)$ 
        % propone nuevos sensores en variables desconocidas
4   $pob = pob + G'$ 
5  fin
6  repita mientras no ( $Detect(G'_i) \neq true \forall G'_i \in pob$ ) o  $Nb\_generaciones$  hacer
7  inicio
        % inicia el ciclo reproductivo
8      Reproducción ( $pob$ )
9  fin
10 si  $\exists Detect(G'_i) = true \forall G'_i \in pob$  entonces
11 inicio
12 repita para  $\forall G'_i \in pob$  donde  $Deteccion(G'_i) = verdad$ 
13 inicio
14  $cost_i = \sum_j^{#vd} (ind.Cost) * (ind.valor)$ 
        % Para cada sensor ( $ind.valor$ ) existe un costo ( $ind.costo$ ). Cada valor de 1 de  $ind.valor$ 
        % en el gen del individuo  $i$  significa un sensor  $j$  escogido, donde  $vd$  es el número de
        % variables desconocidas
15 fin
16  $FF_3 = \min_i(cost_i)$ 
        % selecciona la configuración con menor costo
17  $G' = G'_i$  donde  $\min_i(cost_i)$ 
18 fin
19 Sino
20  $cost = \emptyset$ 
21 fin

```

Algoritmo 4.7. - Generación de población aleatoria AG3.

Algoritmo **generacion_aleatorea(G)**

```

1  repita para  $k, #VD$ 
    % ajusta G añadiendo aleatoriamente sensores en variables desconocidas
2       $G' = Modifica(G)$ 
    %  $G'$  con la nueva configuración de sensores
3  fin

```

Lema 3: Sea G un modelo del sistema, existe un G' que será el mejor individuo de AG3, con una modificación de G que incrementa la observabilidad del sistema, al proponer un nuevo modelo estructural del mismo con la inclusión de nuevos sensores, cuyo costo de implantación es el mínimo evaluado por FF_3 .

Prueba del Lema3; Las modificaciones G' en el sistema G incluyen nuevos sensores en él, lo que permite incrementar su observabilidad al adicionar ecuaciones que representan los nuevos sensores, tal que $|X_{G'}| < |X_G|$, como lo muestran las Figuras 4.3 y 4.5. Esta adición de ecuaciones en el grafo bipartito, implica que se debe rehacer el proceso de verificación de la propiedad de diagnosticabilidad en la nueva población de G' , usando el Algoritmo 4.2. Ese algoritmo permite determinar, mediante AG1 y AG2, la nueva población de MSOS por cada G' , y además, determinar si cumplen con la propiedad de diagnosticabilidad (cada G' que lo cumpla, representa una solución al problema de localización de sensores para el sistema). Finalmente, para cada G' que cumpla con la propiedad de diagnosticabilidad, el costo de implantación de sus sensores es evaluado con FF_3 ver ecuación (4.15), tal que AG3 escoge el G' de menor costo (ver línea 16 de algoritmo AG3).

Sea la Figura 4.5 y la Tabla 4.12 una posible modificación (G') del modelo presentado en la Figura 4.1, la cual adiciona una ecuación más al modelo, implantando un nuevo sensor en x_1 .

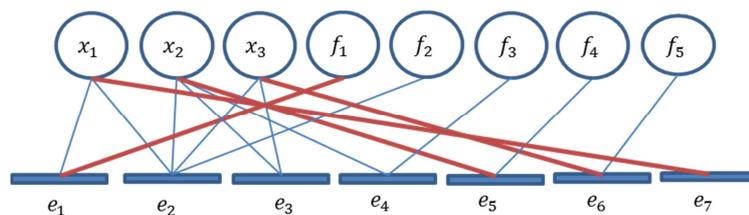


Figura 4.5 -Posible modificación de modelo de la Figura 3.2.

Tabla 4.12 - Representación de un individuo en la población del AG3 a partir de G .

<i>REPRESENTACIÓN DEL INDIVIDUO</i>	
G	[110000;011110;011001;100000;010000;000010;000001;000000]
G'	[1100001;0111100;0110010;1000000;0100000;0000100;0000010;0000010;000010];

La función de evaluación de AG3 considera el mínimo costo, al momento de la evaluación de los individuos propuestos, determinado por la FF_3 en (4.13) (ver línea 16 del Algoritmo 4.6), solo si el resultado de la *Detección* es verdad (ver líneas 10 y 12 del Algoritmo 4.6). Así, dentro de la población de posibles soluciones se elige el menor costo global de implantación de cualquier combinación de sensores propuesta, caracterizada por la ecuación:

$$FF_3 = \min_i(cost_i) \quad (4.15)$$

En general, el enfoque analítico aquí desarrollado determina si todas las fallas consideradas en un sistema pueden ser detectadas y aisladas unas de las otras. Para ello, en primera instancia obtiene un modelo estructural analítico, donde se identifican las ecuaciones de soporte de prueba, y en función a las mismas se ejecuta los algoritmos propuestos, AG1 propone las redundancias analíticas con un grado igual a 1 (MSOS), AG2 selecciona una población de MSOS óptimos construyendo una MFF, y en el caso que el sistema original tenga alguna de las dos propiedades de diagnosticabilidad, AG3 propone la inclusión de nuevos sensores para el incremento de la redundancia. Esta técnica puede ser utilizada para cualquier caso real, en el que se pueda construir un modelo analítico del mismo.

4.4. METODOLOGÍA PARA USAR LOS AG EN CASOS REALES

A continuación se indica para cada AG, los parámetros que deben ser especificados, y las consideraciones a hacer en cada caso. Para el caso de AG1, se debe especificar:

- Estructura del individuo (C): Como se explica en la Sección 4.2.1, C es una cadena de bits que modela un grafo bipartito G , que a su vez representa un análisis estructural del sistema bajo estudio. Está definido por los posibles arcos entre las variables que resultan de la unión del conjunto de las fallas y el conjunto de las variables desconocidas $G = G_X \cup G_F$, y su relación con las ecuaciones (E) que describen el sistema. La población consiste en la generación aleatoria de cincuenta (50) individuos.

- Operadores Genéticos: En este caso se determina el uso de operadores genéticos clásicos, el de cruce con una probabilidad de 0.7, y el de mutación con una probabilidad de 0.9, siendo esto suficiente para observar modificaciones considerables en los individuos de las futuras generaciones.

- Numero de generaciones: Como mínimo se realizan veinte (20) iteraciones por cada falla considerad; sin embargo, si no se obtienen resultados favorables en esta cantidad de iteraciones, el AG continua las generaciones hasta que se alcance el criterio de parada.

- Criterio de parada: el AG se detendrá al momento que los dos mejores individuos no sufran modificaciones en 20 generaciones consecutivas para la falla considerada en ese momento. Luego se vuelve a invocar el algoritmo, hasta haber estudiado cada una las fallas en estudio.

Para el AG2, se debe especificar:

- Estructura del individuo (A): Esta representado por una cadena de bit, cada bit representa a un MSOS resultante del AG1, como se muestra en la Figura 4.4 y en la Tabla 4.4. Además, en este caso se decidió crear una población de veinte (20) individuos.

- Operadores Genéticos: En este caso, al igual que en el AG1 se determina el uso de operadores genéticos clásicos como el de cruce con una probabilidad de 0.7 y de mutación con una probabilidad de 0.9, siendo estos suficientes para observar modificaciones considerables en los individuos de las futuras generaciones.

- Número de generaciones: Al igual que el AG1, como mínimo se realizan veinte (20) iteraciones. Sin embargo, si no se obtienen resultados favorables en esta cantidad de iteraciones, el AG continúa las generaciones hasta que se alcance el criterio de parada.

- Criterio de parada: el AG se detendrá al momento en que los dos mejores individuos (conjunto de MSOS seleccionados) no sufran modificaciones en 20 generaciones consecutivas.

Los parámetros del AG3 son:

- Estructura del individuo (G'): El objetivo del AG3 es realizar modificaciones en el modelo estructural original, por lo que se tomó la misma premisa del AG1 para la representación del individuo.

- Número de generaciones: como mínimo se realizan cinco (5) iteraciones, por ser un algoritmo más pesado computacionalmente (invoca a los otros dos). Sin embargo, si no se obtienen resultados favorables en esta cantidad de iteraciones, el AG continúa las generaciones hasta que se alcance el criterio de parada.

- Criterio de parada: el AG se detendrá al momento en que los dos mejores individuos (G') no sufran modificaciones en 5 generaciones consecutivas.

Además, para el AG3 se usaron los mismos valores de parámetros que los de los AG anteriores, en cuanto a los operadores genéticos, criterios básicos que logran cumplir con los requisitos exigidos.

4.5. ANÁLISIS DE DIAGNOSTICABILIDAD BASADO EN EL MODELO INTELIGENTE PARA SISTEMAS CONTINUOS.

A lo largo del Capítulo 4 se propone un enfoque para calcular relaciones de redundancia analíticas (ARR) y un modelo estructural para el análisis de diagnosticabilidad en procesos continuos, utilizando AG [54, 55]. En esta sección se muestra el uso de la técnica inteligente aquí descrita, tanto en el modelo no lineal utilizado en la Sección 3.7.1, como en el caso de estudio petrolero.

4.5.1. ANÁLISIS DE DIAGNOSTICABILIDAD CON AG EN UN SISTEMA CONTINUO.

El modelo planteado en la Sección 3.7.1, de un sistema continuo, es la entrada al algoritmo desarrollado en este capítulo, para realizar el análisis de diagnosticabilidad. El

análisis estructural del modelo es a través del grafo bipartito mostrado en la Figura 3.2, y su representación como un individuo de AG1 es una cadena de bits, tal como se explica en la Sección 4.2.1. La Tabla 4.13 muestra el individuo G , que está conformado por la unión de G_X , con una longitud de 18 bits (son 3 variables desconocidas y 6 ecuaciones, con un arco entre cada uno de los subconjunto), y G_F con una longitud de 30 bits (en este caso son 5 fallas y las mismas 6 ecuaciones), es decir, $G = G_X \cup G_F$.

El algoritmo llamado *Principal* (Algoritmo 4.1) invoca al algoritmo *Detección* (Algoritmo 4.2), para la determinación de una población de MSOS sensible a cada falla en estudio en el modelo, y cumplir con la detectabilidad del sistema. Además, construye la matriz de firmas de fallas con el mínimo conjunto de MSOS necesarios para cumplir con la propiedad de aislabilidad del sistema. El algoritmo *Detección* realiza el llamado a AG1 (Algoritmo 4.4) y a AG2 (Algoritmo 4.5), respectivamente, para realizar esta tarea.

Tabla 4.13- Representación del individuo del modelo de la Figura 3.2.

G	
G_X	[1,1,0,0,0,0;0,1,1,1,1,0;0,1,1,0,0,1];
G_F	[1,0,0,0,0;0,1,0,0,0;0,0,0,0,0;0,0,1,0,0;0,0,0,1,0;0,0,0,0,1];

La población inicial de AG1 es de 50 individuos, estos individuos son sub-modelos estructurales del modelo principal, lo cual es suficiente para cumplir con los requerimientos iniciales para ser MSOS. Estos individuos son evaluados usando la función objetivo FF_I , y cada generación AG1 selecciona los mejores individuos como padres, para ejecutar sobre ellos los operadores genéticos de cruce, con una probabilidad de 0.7, y de mutación, con una probabilidad de 0.9. El criterio de parada es: si el individuo con mejor valor de aptitud no mejora en 50 iteraciones el AG1 se detiene.

En primera instancia, AG1 estudia individualmente cada falla, y posteriormente, si no consigue MSOS sensibles a cada falla individualmente, las combina hasta encontrar MSOS sensibles a las fallas consideradas, debido a que es posible que se encuentren MSOS sensible a dos o más fallas. El resultado de AG1 es una población de MSOS sensibles a las fallas consideradas. La Tabla 4.14 muestra que el algoritmo encuentra nueve MSOS, a diferencia de los seis encontrados en la Sección 3.7.1. Los MSOS adicionales encontrados

no mejoran el resultado obtenido por el algoritmo propuesto en [21] (en cuanto a la propiedad de diagnosticabilidad del sistema), solo que existe una mayor población de MSOS en el modelo.

Ahora bien, la diferencia se puede observar al obtener el resultado del AG2 mostrado en la Tabla 4.15, donde con cinco MSOS es suficiente para tener el mismo resultado que la Tabla 3.7 (usan 6 MSOS).

Tabla 4.14- Conjuntos de MSOS generados por los AG.

MSOS PARA TODAS LAS FALLAS	
MSOS	[3 5 6]
	[3 4 6]
	[4 5]
	[4 6]
	[1 2 4 6]
	[1 2 5 6]
	[1 2 3 6]
	[1 2 3 5]
	[1 2 3 4]

AG2 comienza con una población de 20 individuos evaluados por la función objetivo FF_2 , luego, al igual que AG1, los mejores individuos son escogidos como padres en cada generación, y se ejecuta sobre ellos los operadores genéticos de cruce y mutación. El proceso de generación de nuevos individuos se realiza dirigido, al compararse con el individuo del modelo original, ya que los individuos no pueden generar arcos activos que no estén contenidos entre los posibles arcos del grafo bipartito original. En ese sentido, los operadores proponen cambios aleatorios para generar nuevos individuos, pero se corrigen los individuos para garantizar que los nuevos arcos activos correspondan a arcos existentes en el grafo bipartito original. Por otra parte, el criterio de parada en esta ocasión hace que se detenga cuando el mejor individuo no mejora luego de 20 iteraciones.

Tabla 4.15- MFF generado por AG2.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	0	0	1
Arr_2	0	1	1	0	1	0
Arr_3	0	0	0	0	1	1
Arr_4	0	1	1	1	0	0
Arr_5	0	0	0	1	0	1

C7	0	1000	40000	41000
C8	100	0	40000	40100
C9	0	1000	40000	41000
C10	0	0	40000	40000
C11	0	1000	40000	41000
C12	100	1000	40000	41100
C13	100	1000	40000	41100
C14	100	1000	40000	41100
C15	0	1000	40000	41000
C16	0	0	40000	40000
C17	100	1000	40000	41100
C18	0	1000	40000	41000
C19	0	1000	40000	41000
C20	0	1000	40000	41000
C21	0	1000	40000	41000
C22	0	0	40000	40000
C23	0	1000	40000	41000
C24	0	1000	40000	41000
C25	0	1000	40000	41000
C26	0	1000	40000	41000
C27	0	1000	40000	41000
C28	0	1000	40000	41000
C29	0	1000	40000	41000
C30	0	1000	40000	41000
C31	0	1000	40000	41000
C32	0	1000	40000	41000
C33	100	1000	40000	41100
C34	100	1000	40000	41100
C35	100	0	40000	40100
C36	100	1000	40000	41100
C37	0	1000	40000	41000
C38	0	1000	40000	41000
C39	0	1000	40000	41000
C40	0	1000	40000	41000
C41	0	1000	40000	41000
C42	0	1000	40000	41000
C43	0	1000	40000	41000
C44	0	1000	40000	41000
C45	0	1000	40000	41000
C46	0	1000	40000	41000
C47	0	1000	40000	41000
C48	0	1000	40000	41000
C49	0	1000	40000	41000
C50	0	0	40000	40000

Como el propósito es obtener el mínimo valor de FF_1 , luego de la evaluación de la población inicial se toman los mejores individuos, es decir, aquellos con el menor valor, y se pasan por los procesos de generación de nuevos individuos usando los operadores genéticos (cruce y mutación). Luego se seleccionan los mejores, para generar una nueva población de cincuenta individuos. La Tabla 4.18 muestra la población final del proceso evolutivo del AG1 para f_1 .

Tabla 4.18- Evaluación de la población final para el estudio de f_1 .

<i>Individuo</i>	<i>P1</i>	<i>P2</i>	<i>P3</i>	<i>FF1</i>
<i>C1</i>	0	0	0	0
<i>C2</i>	0	0	0	0
<i>C3</i>	0	0	10000	10000
<i>C4</i>	0	0	10000	10000
<i>C5</i>	0	0	0	0
<i>C6</i>	0	0	10000	10000
<i>C7</i>	0	0	0	0
<i>C8</i>	0	0	10000	10000
<i>C9</i>	0	0	0	0
<i>C10</i>	0	0	10000	10000
<i>C11</i>	0	0	10000	10000
<i>C12</i>	0	0	10000	10000
<i>C13</i>	0	0	0	0
<i>C14</i>	0	0	10000	10000
<i>C15</i>	0	0	10000	10000
<i>C16</i>	0	0	10000	10000
<i>C17</i>	0	0	10000	10000
<i>C18</i>	0	0	0	0
<i>C19</i>	0	0	10000	10000
<i>C20</i>	0	0	10000	10000
<i>C21</i>	0	0	0	0
<i>C22</i>	0	0	10000	10000
<i>C23</i>	0	0	10000	10000
<i>C24</i>	0	0	0	0
<i>C25</i>	0	0	10000	10000
<i>C26</i>	0	0	0	0
<i>C27</i>	0	0	10000	10000
<i>C28</i>	0	0	10000	10000
<i>C29</i>	0	0	10000	10000
<i>C30</i>	0	0	10000	10000
<i>C31</i>	0	0	10000	10000
<i>C32</i>	0	0	10000	10000
<i>C33</i>	0	0	10000	10000
<i>C34</i>	0	0	10000	10000
<i>C35</i>	0	0	10000	10000
<i>C36</i>	0	0	10000	10000
<i>C37</i>	0	0	10000	10000
<i>C38</i>	0	0	10000	10000
<i>C39</i>	0	0	10000	10000
<i>C40</i>	0	0	10000	10000
<i>C41</i>	0	0	10000	10000
<i>C42</i>	0	0	10000	10000
<i>C43</i>	0	0	0	0
<i>C44</i>	0	0	10000	10000
<i>C45</i>	0	0	10000	10000
<i>C46</i>	0	0	10000	10000
<i>C47</i>	0	0	10000	10000
<i>C48</i>	0	0	10000	10000
<i>C49</i>	0	0	10000	10000
<i>C50</i>	0	0	10000	10000

En la Tabla 4.18, los individuos C con valor igual a cero para FF_1 son MSOS para f_1

(en este caso 11 MSOS).

Por otra parte, dado que los AG son heurísticos, los individuos de la población final pueden ser repetidos, o incluso diferentes, en cada corrida realizada; es por esto que se realiza un análisis estadístico de los resultados. Esto es válido, tanto cuando se evalúa cada falla individualmente, o cuando se evalúan combinaciones de ellas (en el caso que no se obtengan MSOS individualmente para cada falla), para obtener MSOS. En el presente caso de estudio, se analizan los resultados (población final) luego de treinta corridas de AG1, tanto para f_1 como para f_2 . En la Tabla 4.19 se muestran los 5 MSOS que aparecen más frecuentes en las 30 corridas del AG1, tanto para f_1 como para f_2 .

Tabla 4.19- Población de MSOS para f_1 y f_2 .

MSOS para f_1	[1,2,3,4,5,7,9,12,13,14,20,21,23,24]
	[1,2,3,4,5,7,9,12,13,14,20,21,23,24]
	[1,2,3,4,5,7,8,9,10,11,12,13,14,15,20,21,24]
	[1,2,3,4,5,7,8,9,10,11,12,13,14,15,19,20,21,22,23,24]
	[1,3,4,5,7,8,9,10,11,12,13,14,15,16,17,18,19,22]
MSOS para f_2	[1,3,5,6,7,8,9,10,11,12,13,14,15,18,19,20,22,23,24]
	[1,2,5,6,7,8,9,10,11,12,13,14,15,18,19,21,22,23,24]
	[1,2,3,5,6,7,8,9,10,12,13,14,15,18,19,20,22,23,24]
	[1,2,3,6,7,8,9,10,11,13,14,15,18,19,21,22,23]
	[1,3,5,6,7,8,9,10,11,13,14,15,18,19,22,23,24]

A diferencia del algoritmo utilizado en la Sección 3.7.2, AG1 encuentra una población de MSOS sensible a cada falla (o a combinaciones de ellas) en cada corrida (ver Tabla 4.19). Se genera una población de MSOS desde las diferentes corridas realizadas, la cual es usada para generar una primera matriz de firmas de fallas. Esa es la entrada de AG2, que la use como semilla para generar su población inicial, y después se encarga de encontrar los mínimos MSOS necesarios para obtener la aislabilidad del sistema. Para el presente caso de estudio, la Tabla 4.20 muestra los MSOS necesarios para cumplir con la propiedad de aislabilidad determinados por AG2, y en la Tabla 4.21 la matriz de firma de falla resultante.

considerada. Este es un resultado muy importante de la presente propuesta, ya que posibilita un análisis más amplio de la propiedad de diagnosticabilidad en un sistema. Posteriormente, el AG2 arroja una matriz de firma de fallas que muestra la aislabilidad completa del sistema, la cual se muestra en la Tabla 4.24 [54], eligiendo un MSOS para cada falla (algo que no es posible obtener en el enfoque propuesto en [21]).

Tabla 4.23- Población de MSOS conseguidas por AG1 para las 5 fallas.

MSOS para f_1	[1,2,3,4,5,7,8,9,11,14,18,19,20,21]
	[1,2,3,4,5,7,8,10,11,14,19,20,21,23]
	[3,4,5,7,8,9,11,14,16,17,18,19,20,21,22,24]
	[1,2,3,4,5,7,8,9,11,14,16,17,19,20,21,22,23,24]
MSOS para f_2	[1,2,3,5,6,7,8,10,11,14,16,17,18,19,23,24]
	[1,2,3,5,6,7,8,9,10,11,14,16,17,18,19,20,23,24]
	[5,6,10,11,14,23,24]
MSOS para f_3	[1,2,3,5,7,8,9,10,11,14,15,16,17,18,19,20,21,22,23,24]
	[3,5,9,10,11,15,22,23]
MSOS para f_4	[1,2,5,7,8,9,10,11,13,14,16,17,18,19,21,23,24]
	[1,2,3,5,7,9,10,11,13,14,16,17,18,19,20,21,23]
MSOS para f_5	[1,2,5,7,8,9,11,12,14,16,17,21]
	[1,2,3,5,7,10,12,14,16,17,19,22,23]

En las pruebas realizadas en esta sección, se puede observar como el enfoque propuesto en este trabajo es capaz de generar una población amplia de MSOS sensibles a una falla o a combinaciones de ellas (AG1), posibilitando un mejor análisis de la propiedad de detectabilidad. Posteriormente, basado en esa población, es capaz de realizar un análisis exhaustivo de la propiedad de aislabilidad del sistema, lo que hace que el enfoque desarrollado en este trabajo mejore el análisis de diagnosticabilidad. En específico, determina el grupo óptimo de MSOS que verifiquen esa propiedad (AG2) en el sistema (cuando existe). Las técnicas en la literatura no posibilitan eso, como en [21], que es donde introducen la técnica de TES, además que no construyen una matriz de firma de fallos, problema que resuelve también este enfoque. Particularmente, obtener los MSOS óptimos de las fallas del sistema es un problema combinatorio que los AG resuelven muy bien (ver AG1). Esa nueva población de MSOS da un espacio amplio de posibilidades para construir la matriz de firmas de fallas que posibilite la aislabilidad del sistema (ver AG2), algo que no ocurre en

los otros enfoques propuestos en la literatura por el número restringido de MSOS que ellos obtienen.

Tabla 4.24- MFF para el análisis de cinco fallas, usando el algoritmo propuesto.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	0	0	0	0
Arr_2	0	0	1	0	0	0
Arr_3	0	0	0	1	0	0
Arr_4	0	0	0	0	1	0
Arr_5	0	0	0	0	0	1

4.6. LOCALIZACIÓN DE SENSORES BASADA EN EL MODELO INTELIGENTE

4.6.1. LOCALIZACIÓN DE SENSORES CON AG

Para el ejemplo mencionado en la Sección 3.8.1, se ejecuta el algoritmo de *Localización* propuesto en este trabajo, tal y como es descrito en la Sección 4.3 [55]. Este algoritmo propone una población de sensores, que son evaluados en el algoritmo *Detección* para ver si cumplen con la propiedad de diagnosticabilidad. El algoritmo modifica el modelo original agregando ecuaciones que representan los nuevos posibles sensores a instalar, como se observa en la Figura 4.6, para el caso de un nuevo sensor (ecuación e_7) para x_1 . Otra particularidad del algoritmo es que se analizan los costos asociados a la implantación de los nuevos sensores (AG3 elige la configuración de sensores de menor costo que garantiza la propiedad de diagnosticabilidad).

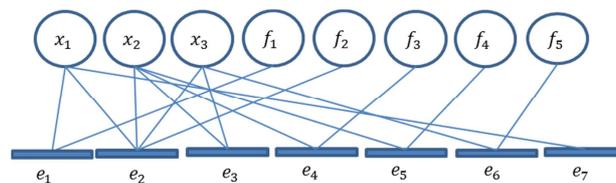


Figura 4.6- Grafo bipartito del ejemplo anterior en el que se agrega un sensor en x_1 .

Tabla 4.25 - MFF resultado del algoritmo de Localización propuesto.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	0	0	0	0
Arr_2	0	1	1	1	0	0
Arr_3	0	0	1	0	1	1
Arr_4	0	0	0	1	1	0
Arr_5	0	0	0	1	0	1
Arr_6	0	0	0	0	1	1

El resultado de AG3 indica que se debe instalar un sensor en x_1 para que f_1 y f_2 sean aislables una de la otra. La Tabla 4.25 muestra la nueva matriz de firma de fallas (se ve que todas las fallas son aislables unas de las otras), y en la Figura 4.6 el modelo estructural que representa la inclusión del sensor en x_1 . Nuevamente, a diferencia del algoritmo propuesto en [7] (que propone 10 MSOS), se demuestra que con 6 MSOS es suficiente para obtener una aislabilidad completa del sistema, a pesar de haberse encontrado una población grande de residuos.

AG3 explora las posibles combinaciones de los potenciales sensores relacionados con las fallas en estudio. Para ello, AG3 propone una población de individuos que representan posibles sensores a añadir para observar las variables relacionadas con las fallas en estudio, e invoca al algoritmo de *Detección* para verificar si alguno de ellos cumple con la propiedad de diagnosticabilidad. AG3 ejecuta este trabajo hasta que algún individuo cumpla con la propiedad de diagnosticabilidad, o un número de 20 iteraciones sin una mejora en los individuos. Por otra parte, si AG3 obtiene varios individuos que cumplan con la dicha propiedad, los evalúa usando FF_3 (para escoger el que tenga el mínimo costo de implantación).

4.6.2. LOCALIZACIÓN DE SENSORES CON AG EN UN POZO LAG

En función de validar el funcionamiento del algoritmo de localización de sensores en el caso de estudio petrolero, se modificaron las variables que están siendo medidas según la Sección 3.7.2 [55]. Para el análisis de diagnosticabilidad en el nuevo modelo, solo se mantienen las mediciones de las variables y_1, y_2, y_3 y y_7 , se dejan de medir el resto de

variables; es decir, se eliminan los sensores inicialmente propuestos, con el cual el nuevo modelo estructural es el mostrado en la Figura 4.7, al agregar al modelo analítico mostrado en la Sección 2.4.3 las ecuaciones desde (4.16) a la (4.19).

$$y_1 = x_1 \quad (4.16)$$

$$y_2 = P_{ai} \quad (4.17)$$

$$y_3 = P_t \quad (4.18)$$

$$y_7 = P_r \quad (4.19)$$

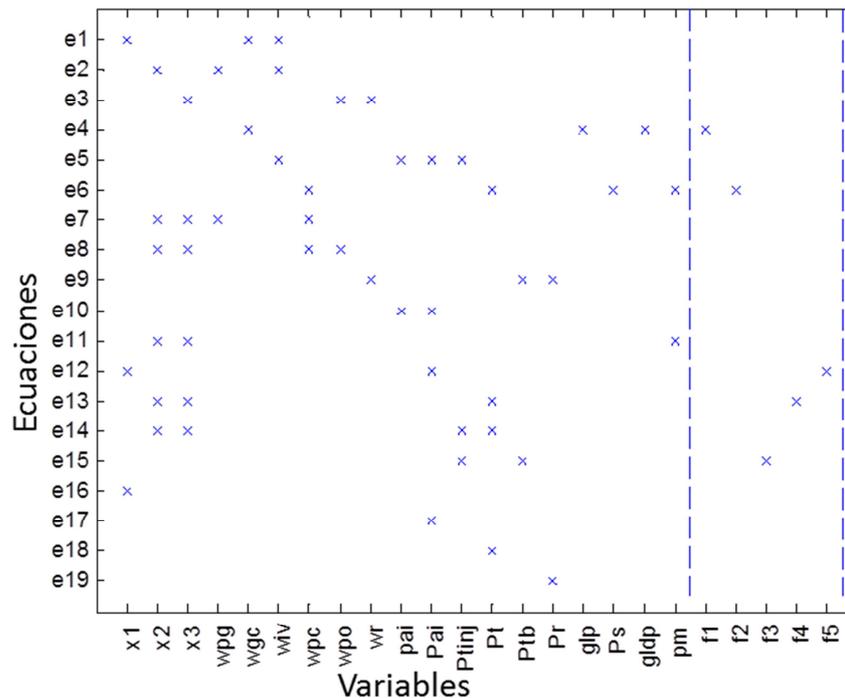


Figura 4.7 -Matriz de incidencia del Sistema LAG con cuatro variables sensadas.

El resultado del análisis de diagnosticabilidad para el nuevo modelo del sistema LAG con cinco fallas, arroja que el mismo no cumple con esta propiedad al no poder aislar las fallas f_3 , f_4 y f_5 , esto es debido a que la redundancia del sistema decrece debido a que son menos las variables medidas. La Tabla 4.26 muestra la matriz de firma de fallas resultante de la evaluación de los algoritmos genéticos inmersos en el algoritmo de detección. Por lo antes descrito, el análisis invoca al algoritmo de localización de sensores para determinar la posible ubicación de sensores que permitan incrementar la redundancia del sistema, y así poder cumplir con la propiedad de diagnosticabilidad.

Tabla 4.26- MFF resultado del análisis con solo cuatro variables medidas.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	1	1	1
Arr_2	0	1	0	1	1	1
Arr_3	0	0	0	1	1	1

Como se ha explicado en la Sección 4.3, el algoritmo de *Localización* realiza un llamado a AG3, el cual propone una población de posibles sensores (G'), adicionando ecuaciones que corresponden a la inclusión de posibles sensores y modificando el modelo original G . Los nuevos sensores propuestos incrementan la redundancia del sistema LAG. La población de G' es evaluada por el algoritmo *Detección*, de manera de verificar que se cumpla con la propiedad de diagnosticabilidad en el sistema.

En general, el algoritmo de *Localización* adiciona aleatoriamente una ecuación más en el modelo (propuesta de un nuevo sensor), y va evaluando G' según el sensor propuesto. En las Tablas 4.27, 4.28 y 4.29 se muestran las matrices de firmas de fallas resultante del análisis proveniente de la propuesta de un sensor para medir u observar w_{gc} , o un sensor para glp , o uno para $gldp$, respectivamente. Posteriormente, AG3 evalúa estos resultados con la función de aptitud descrita en la ecuación (4.9), que no es más que el mínimo costo de implantación de los sensores propuestos.

En particular, en los sistemas LAG las variables de superficie tienen menor costo que las variables de fondo, y a su vez en las variables de superficie los sensores de presión son de menor costo que los sensores de flujo másico. Por tal motivo, según los datos incluidos en la función de costo del AG3, la variable X_{18} , la cual equivale a $gldp$, es la seleccionada, como se describe en la Sección 2.4, la cual es la presión diferencial medida a través de una placa orificio. Por otra parte, se puede corroborar el cumplimiento de la propiedad de diagnosticabilidad analizando la MFF mostrada en la Tabla 4.27, donde se aprecia que todas las fallas son sensibles a al menos un residuo. Además, se pueden identificar todas las fallas consideradas, ya que sus firmas en la matriz son distintas unas de las otras una, garantizada por la independencia línea de la matriz (la propiedad de diagnosticabilidad se cumple en el sistema, al añadir cualquiera de los tres sensores propuesto por AG3, ver Tablas 4.27 a 4.29).

Tabla 4.27 -MFF resultado del AG3 proponiendo un sensor en $gldp$.

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	0	1	0	1
Arr_2	0	1	0	1	1	0
Arr_3	0	0	1	1	0	0
Arr_4	0	0	1	0	0	1
Arr_5	0	0	0	1	0	0
Arr_6	0	1	1	0	1	1

Tabla 4.28-MFF resultado del AG3 proponiendo un sensor en glp .

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	0	0	0
Arr_2	0	0	1	1	1	1
Arr_3	0	1	1	1	1	0
Arr_4	0	0	0	1	0	0
Arr_5	0	0	0	1	0	0
Arr_6	0	1	1	0	1	1

Tabla 4.29-MFF resultado del AG3 proponiendo un sensor en w_{gc} .

	N	f_1	f_2	f_3	f_4	f_5
Arr_1	0	1	1	0	1	0
Arr_2	0	0	1	1	1	1
Arr_3	0	1	1	1	0	1
Arr_4	0	0	0	1	0	0
Arr_5	0	0	0	1	0	0
Arr_6	0	1	1	0	1	1

De las Tablas 4.27, 4.28 y 4.29, se puede corroborar el cumplimiento del *Lema 3*, dado que el AG3 escoge al sensor de menor costo, y al distinguir la diagnostibilidad analizando los resultados de la MFF en coherencia con el *Lema 2*.

La Figura 4.8, como se ha explicado en secciones anteriores, muestra la matriz de incidencia del modelo del sistema, cómo quedaría con la inclusión del nuevo sensor propuesto por AG3, y no es más que la inclusión de la ecuación resultante de la ejecución de AG3, que él selecciona por ser su individuo con menor costo de implantación.

$$y_7 = Gldp \quad (4.19)$$

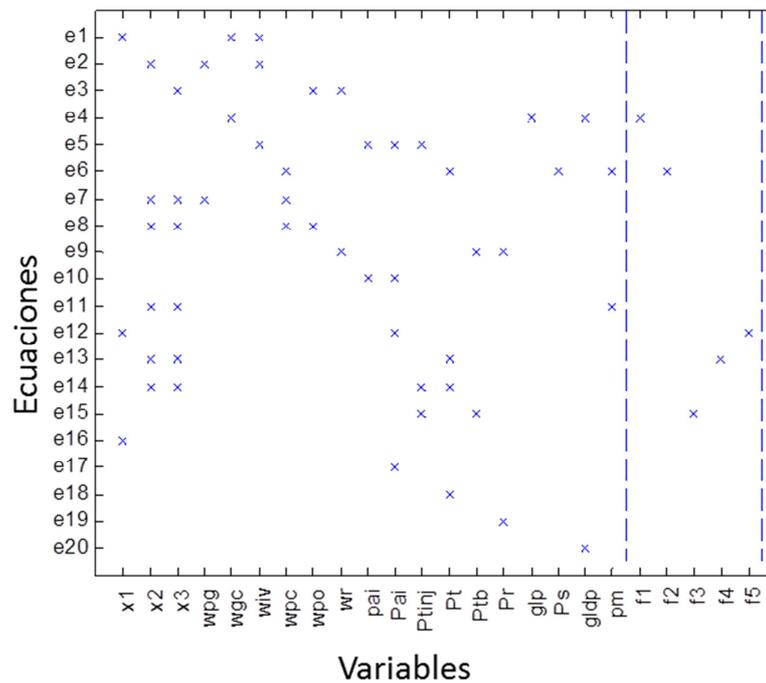


Figura 4.8 -Matriz de incidencia del Sistema LAG resultado de la ejecución del AG3

El análisis de la Figura 4.8 igual que la Figura 4.3, representa la relación entre las variables y ecuaciones. En particular con la inclusión del nuevo sensor vemos que aparece la expresión representada por la ecuación (4.19), siendo esta la presión diferencial de inyección de gas al pozo para el levantamiento de petróleo agregado en la ecuación $e20$ [55].

4.7. COMPARACIÓN DE LOS RESULTADOS

Todos los experimentos que se mostraron en el Capítulo 3 y en esta sección, se realizaron con técnicas FDI basadas en relación de redundancia analítica, determinadas por una ecuación de soporte. La razón de ello es que el enfoque inteligente tiene las mismas bases teóricas.

Por tal motivo, en primera instancia se realizó el estudio de diagnosticabilidad en sistemas continuos con el algoritmo propuesto en [21], donde se practica el análisis estructural de los sistemas realizando modelos parciales del mismo. Particularmente, el algoritmo entra en un proceso recursivo donde obtiene un MTES a la vez para una falla

considerada, para posteriormente pasar a buscar otro MTES para otra falla, y así sucesivamente. Ese algoritmo depende del orden en el cual se colocan las ecuaciones y el orden con el cual se buscan las fallas, por lo que no necesariamente obtiene los mejores MTES para un modelo. El uso de AG para la búsqueda de MSOS resulta ser más eficaz, dado a que no importa el orden como se organicen las ecuaciones del modelo. AG1 explora una población de MSOS y las evalúa mediante la función objetivo FF_I ; por otro lado, AG1 consigue una población de MSOS por fallas, y no uno solo como el algoritmo con que se está comparando [21]. Esto se puede observar al comparar las Tablas 3.7 y 4.11. Otra diferencia es que se obtiene MSOS y no MTES, siendo un MSOS un MTES de importante características, dado que es el mínimo subconjunto de ecuaciones del modelo en una ecuación de soporte garantizando que esta redundancia sea igual a 1. Eso no lo garantiza el algoritmo propuesto en [21].

Por otra parte, AG2 construye una matriz de firma de fallas que cumple con la propiedad de diagnosticabilidad en función de los resultados de AG1, a diferencia de otros algoritmos que terminan los resultados con los residuos encontrados, para su posterior análisis. AG2 construye la matriz de firma de fallas óptima, tal que selecciona la menor cantidad de MSOS que aseguren la detectabilidad y aislabilidad del sistema, como se puede observar al comparar la Tabla 3.8 con la Tabla 4.12 (caso sistema no lineal), y la Tabla 3.12 con la Tabla 4.22 (caso no lineal con localización de sensores). Así, el resultado final de AG2 es una MFF óptima. Los resultados de las Tablas 4.11, 4.16 y 4.20 se construyeron a partir de treinta corridas de AG2, eligiéndose los individuos con mayor frecuencia (mínimo de 30% de apariciones).

En otro orden de ideas, al comparar el comportamiento del algoritmo propuesto en [7], que propone una localización de sensores basado en el análisis de diagnosticabilidad con análisis de redundancias de fallas considerando ecuaciones de soportes (MTES) [21], con el propuesto en este trabajo [55], se observa que el enfoque propone una población aleatoria de posibles sensores modificando el modelo estructural original, lo que brinda una gran ventaja por el abanico de posibles soluciones que analiza. Bajo este esquema, el algoritmo *Localización* propuesto en este trabajo llama a AG1 y AG2, para evaluar la

propiedad de diagnosticabilidad en la población de posibles soluciones previamente generada. De esta manera, se garantiza que los nuevos sensores propuestos aseguren la propiedad de diagnosticabilidad en el sistema. Los resultados de las Tablas 4.24 a la 4.26 permiten verificar ese comportamiento del AG3 (base del algoritmo *Localización* propuesto) [55]. Adicionalmente, este algoritmo evalúa la función objetivo en los individuos resultantes, seleccionando aquellos individuos cuyos costos de implantación del sensor sean mínimos, para de esta manera reducir el costo en el sistema de producción. Esto último es una diferencia (ventaja) importante del algoritmo propuesto en este trabajo con respecto a [7], el cual no considera dichos costos.

Por otro lado, al comparar el enfoque propuesto en este trabajo con otros enfoques que han utilizado AG para la localización de sensores, tenemos que en [8] proponen un esquema para optimizar una red de sensores, los cuales están a larga distancia entre sí; lo que es un problema distinto al estudiado en este trabajo, que es en función al análisis de diagnosticabilidad. También, en [9] usan un AG para analizar la mínima cantidad de sensores que optimizan criterios vinculados a costos de implantación, pero no realizan un análisis sobre si incrementan la observabilidad del sistema. Por último, en [4] realizan una propuesta de localización de sensores basada en ARR y la cardinalidad de los sub-conjuntos que conforman los mismos, como en el caso propuesto en este trabajo. Ahora bien, el resultado solo analiza la redundancia de los sistemas, y no considera la calidad de los resultados obtenidos en función al costo de implantación o a las fallas consideradas, lo que arroja una gran cantidad de información innecesaria, agregando mucha complejidad al posterior análisis de diagnosticabilidad.

CAPÍTULO V

CONCLUSIONES Y TRABAJO FUTURO

5.1. CONCLUSIONES

La capacidad de detectar un fallo en el tiempo en un sistema proporciona seguridad, disponibilidad y fiabilidad. Los mecanismos para abordar el problema de detectabilidad y de aislabilidad de fallas abordados en este documento se basan en los principios de diagnóstico con modelos analíticos, con hincapié en el método ARR, extendiéndolo con el uso de AG, con el fin de proponer un enfoque híbrido para el análisis de diagnosticabilidad y localización de sensores.

Los AG fueron usados porque posibilitan definir los problemas de análisis de diagnosticabilidad y de localización de sensores en procesos de producción continua, como problemas de optimización combinatoria.

En el capítulo 4 se utilizan varios AG para solucionar los problemas de análisis de diagnosticabilidad y de localización de sensores, en particular, extendiendo los modelos estructurales de diagnosticabilidad. Eso ha permitido desarrollar un enfoque híbrido basado en técnicas ARR y técnicas inteligentes. De esta manera se crea un modelo inteligente para el análisis de diagnosticabilidad en procesos de producción.

El primer AG tiene una población de grafos bipartitos, y el resultado es el conjunto de MSOS que permite detectar todas las fallas consideradas en el sistema con un grado de redundancia igual a “1”, optimizando el análisis de los resultados al minimizar la complejidad de un ARR. El segundo AG permite alcanzar la propiedad de aislabilidad, al realizar la selección de la población mínima requerida de MSOS; de manera que el AG2 construye la matriz de firma de fallas con los resultados obtenidos del AG1, seleccionando los MSOS necesarios para una completa diagnosticabilidad. El tercer AG realiza modificaciones en el modelo estructural de los sistemas evaluados, proponiendo una población de posibles sensores que permitan alcanzar la propiedad de diagnosticabilidad en aquellos sistemas que no contengan suficiente redundancia. Adicionalmente, evalúa los costos de implantación de los sensores, de tal manera de seleccionar aquellos que tengan el costo mínimo de implantación.

El enfoque propuesto en este trabajo es una herramienta eficaz para resolver la problemática combinatoria detrás de la determinación de MSOS, dado un modelo estructural como grafo bipartito. Además, propone donde deben implantarse nuevos sensores al momento de no obtener el diagnóstico deseado, con el fin de incrementar las relaciones de redundancia del sistema y cumplir con la propiedad de diagnosticabilidad. Eso significa que el enfoque propuesto lleva a cabo varios estudios en forma automática: la determinación de la detectabilidad (logrado con el AG1), la determinación de la aislabilidad de las fallas consideradas en un sistema (a través de AG2), y con ello, la determinación de la propiedad de diagnosticabilidad, y la posibilidad de definir nuevos sensores en el sistema estudiado, incorporando el análisis de los costos de implantación a la toma de decisiones (con el AG3). El tiempo de ejecución de los AGs puede ser controlado a través de sus parámetros, a fin de obtener buenas soluciones en un corto tiempo de cálculo.

En particular, el AG1 estudia la propiedad de detectabilidad basado en el análisis estructural del sistema estudiado. Se trata de un problema de optimización en la búsqueda efectiva de MSOS, porque hay una gran cantidad de caminos alternativos en un sistema, que aumentan según su número de variables y ecuaciones. Estos caminos deben ser analizados, para determinar la propiedad de detectabilidad usando el enfoque de análisis

estructural; es por esto que el AG1 soluciona el problema de optimización combinatoria, evaluando los resultados mediante la función objetivo propuesta en este trabajo. AG2 estudia la propiedad de aislabilidad al analizar la matriz de firmas de falla, con el fin de determinar entre la población de MSOS resultantes del AG1, los mínimos necesarios para determinar si existe; este proceso de selección de MSOS es el problema de optimización que resuelve AG2. AG3 resuelve el problema de optimización combinatoria de evaluar las posibles ubicaciones de sensores en un sistema, para alcanzar la propiedad de diagnosticabilidad en el mismo, al incrementar sus relaciones de redundancia.

En este trabajo se probó la técnica de análisis estructural en un caso del mundo real, un sistema continuo de extracción de petróleo mediante la inyección de gas. Para ese caso no existe en la literatura ningún ejemplo de análisis de diagnosticabilidad, por lo que podría considerarse como el primer paso para el estudio de diagnosticabilidad en este proceso de producción de la industria petrolera. En este contexto, se ha hecho su análisis de diagnosticabilidad según el algoritmo propuesto en [21], y el enfoque propuesto en el Capítulo 4 de este trabajo. Se escogió [21] debido a que los MTES que genera es el punto de partida para generar los MSOS, propuesto en este trabajo. Así, se ha llevado a cabo un análisis considerando varios conjuntos de fallas, y se comparan los resultados entre los dos algoritmos.

Se observa que el enfoque propuesto en este trabajo es excelente buscando MSOS, resultando más eficaz al realizar el análisis del modelo en forma aleatoria, sin importar el orden como se organicen las ecuaciones del modelo, lo cual afecta los resultados propuestos en [21]. AG1 consigue una población de MSOS por fallas, incluso en casos donde hay pocas ecuaciones en el modelo, reduciendo la dificultad para construir residuos. Además, el enfoque propuesto encuentra mejores soluciones que su contraparte, considerando que un MSOS es mejor que un MTES a la hora de realizar el análisis de diagnosticabilidad, al contener un grado de redundancia igual a uno ($\varphi(\mathcal{M}) = 1$).

Con respecto a la localización de sensores, igualmente se hicieron pruebas en los dos casos de estudio, comparando el algoritmo propuesto en este trabajo con el algoritmo

propuesto en [7], determinándose que en ambos casos el algoritmo propuesto en este trabajo encontró soluciones potenciales, seleccionando aquellas con menor costo de implantación (algo que no hace [7]). Todas las propuestas de localización de sensores del algoritmo presentado, llevan al sistema a que cumpla con la propiedad de diagnosticabilidad.

Así, se logra cumplir con el objetivo general; al desarrollar un modelo basado en técnicas inteligentes para analizar la propiedad de diagnosticabilidad en procesos continuos de producción. También, se observa como los objetivos específicos se cumplieron, al estudiar los diferentes métodos de análisis de diagnosticabilidad y de localización de sensores en procesos continuos existentes en la literatura, además, se aplicaron en el caso de estudio (sistema de producción continuo), de igual manera, se extendieron estos métodos con técnicas inteligentes para resolver los problemas planteados.

Por último, se realizó el análisis en un proceso de producción de extracción de petróleo mediante el levantamiento artificial por gas, logrando estudiar tanto las propiedades de detectabilidad y de aislabilidad, así como la localización de nuevos sensores, en el caso de que alguna de las anteriores no se cumpla. Es bueno resaltar que ese análisis se basa en la instrumentación existente y factible en un pozo de producción. De esta manera, se cumplieron todos los objetivos específicos planteados en este trabajo.

5.2. TRABAJOS FUTURO

Un primer trabajo futuro es implantar los algoritmos aquí realizados en un sistema de producción en tiempo real, considerando extender las fallas a analizar según lo determine un equipo de ingenieros de producción en el ámbito de levantamiento artificial de petróleo. Esto ayudará considerablemente a los sistemas de diagnóstico actuales, porque permitirá afinar sus diseños garantizando detectar las inconsistencias en el comportamiento del sistema, discernir cual falla ha ocurrido entre el conjunto de fallas consideradas, entre otros.

Como segundo paso se debe extender el análisis de diagnosticabilidad a otros procesos de producción involucrados en la extracción y manejo del petróleo, tales como

estaciones de flujo, levantamientos artificiales con otros métodos, etc. Para ello, se deben realizar modelos estructurales de estos procesos, y utilizar las técnicas propuestas en esta investigación. Esto permitirá tener sistemas robustos, que tomen decisiones certeras sobre posibles fallas, reduciendo las consecuencias que estas puedan ocasionar en los mismos.

Por otra parte, se deben realizar extensiones al algoritmo de *Localización* de sensores, para realizar análisis de diagnosticabilidad y de ubicación de sensores en un sistema de producción sin variables medidas (instrumentar completamente un sistema). El resultado del mismo no solo indicará la cantidad mínima de sensores necesarios para obtener la propiedad de diagnosticabilidad en un sistema de producción, sino que además será el de mínimo costo de implantación.

BIBLIOGRAFÍA

- [1] L. Travé-Massuyès, T. Escobet, and S. Spanache. “Diagnosability analysis based on component supported analytical redundancy relations”. *IEEE Transactions on Systems, Man, and Cybernetics Part A*: vol. 36, pp. 1146-1160,2006.
- [2] S. Indra, L. Travé-Massuyès, and Elodie Chanthery. “A decentralized FDI scheme for spacecraft: Bridging the gap between model based FDI research & practice”, *In Proceedings the 4th European Conference for Aerospace Sciences*. Saint Petersburg, Russia, 2011.
- [3] F. Nejari, R. Pérez, T. Escobet, “Comparación de técnicas para el estudio de diagnosticabilidad de fallos en sistemas dinámicos.” *Informe Técnico, Dep. Ingeniería de sistemas, Automaticas e informática industrial, Universidad de Catalunya*: Barcelona, España, 2009.
- [4] A. Bhondekar, R.Vig, M. Lal Singla, C. Ghanshyam, P. Ka.“Genetic Algorithm Based Node Placement Methodology For Wireless Sensor Network”. *In Proceedings of the International MultiConference of Engineers and Computer Scientists*: Hong Kong, China, vol. 1, pp. 18 - 20, 2009.
- [5] L. Travé-Massuyès, T. Escobet, and R. Milne. “Model-based diagnosability and sensor placement. application to a frame 6 gas turbine subsystem”, *In Proceedings DX01 twelfth international workshop on principles of diagnosis*: pp. 205–212,2001.
- [6] M. Krysander, E. Frisk “Sensor Placement for Fault Diagnosis” *IEEE Transactions on Systems, Man, and Cybernetics Part A*: vol. 38(6), pp 106-113, 2008.
- [7] E. Frisk, E., M. Krysander, “Sensor placement for maximum fault isolability”. *In Proceedings of 18th international workshop on principles of diagnosis DX-07*: Nashville, TN, pp. 106-113, 2007.

-
- [8] S. Spanache, T. Escobet, L. Travé-Massuyès, “Sensor Placement Optimisation Using Genetic Algorithms”, *In Proceeding DX04, 15th International Workshop on Principles of Diagnosis*: Carcassonne, France, 2004.
 - [9] S. Sen, S. Narasimhan, K. Deb, “Sensor network design of linear processes using genetic algorithms”, *Computers and Chemical Engineering*: London, vol. 22(3), pp. 385–390, 1998.
 - [10] G. Biswas, M. Cordier, J. Lunze, L. Travé-Massuyès, M. Staroswiecki. “Diagnosis of Complex Systems: Bridging the Methodologies of the FDI and DX Communities”, *IEEE Transactions On Systems, Man And Cybernetics Part B*: vol. 34(5), pp. 2159-2162, 2004.
 - [11] M. Nyberg and M. Krysander. “Combining AI, FDI, and statistical hypothesis-testing in a framework for diagnosis”. *In Proceedings of IFAC Safeprocess 03*: Washinton, DC, pp. 813 - 818, 2003.
 - [12] M. Staroswiecki and P. Declerck. “Analytical redundancy in nonlinear interconnected systems by means of structural analysis”. *In Proceedings of IFAC AIPAC’89*: Nancy, France, vol. 2, pp. 23-27, 1989.
 - [13] D. Dustegor, E. Frisk, V. Cocquempot, M. Krysander, M. Staroswiecki, “Structural analysis of fault isolability in the DAMADICS benchmark”. *Control Engineering Practice*: vol. 14(6), pp. 597-608, 2006.
 - [14] M. Di Benedetto, S. Di Gennaro A. D’Innocenzo, “Diagnosability Verification for Hybrid Automata”, *Lecture Notes in Computer Science*: Heidelberg, Germany, vol. 4416, pp. 684-687, 2007.
 - [15] J. Gertler, “Analytical redundancy methods in fault detection an isolation; survey and synthesis”. *In Proceedings IFAC Fault Detection, Supervision and Safety for Technical Processes*, vol. 1, pp 9-22, 1991.

- [16] E. Alcorta. “Detección de fallas mediante redundancia analítica”. *Revista de Ingenierías*: México, vol. 4(11), pp. 43-48, 2001.
- [17] A. Ríos, *Metodologías para la construcción de sistemas de detección y diagnóstico de fallas*, Tesis Doctoral, Universidad de los Andes, Mérida, Venezuela 2003.
- [18] P.M. Frank, “Fault diagnosis in dynamic system using analytical and knowledge based redundancy a survey”: *Automatica*: vol. 26, pp. 459-474, 1990.
- [19] C. Svard, M. Nyberg “A Mixed Causality Approach to Residual Generation Utilizing Equation System Solvers and Differential-Algebraic Equation Theory”, *In Proceedings 19th International Workshop on Principles of Diagnosis DX-08*: Blue Mountains, Australia, 2008.
- [20] C. Svard and M. Nyberg, “Residual generators for fault diagnosis using computation sequences with mixed causality applied to automotive systems”, *IEEE Transactions on Systems, Man, and Cybernetics Part A*: vol. 40(6), pp. 1310–1328, 2010.
- [21] M. Krysander, J. Åslund, and E. Frisk, “A structural algorithm for finding testable sub-models and multiple fault isolability analysis”, *In Proceedings of the 21st International Workshop on Principles of Diagnosis (DX-10)*: 2010.
- [22] M. Krysander, M. Nyberg. “Structural analysis utilizing MSS sets with application to a paper plant”. In Proc. of the Thirteenth International Workshop on Principles of Diagnosis, *In Proceedings 13th International Workshop on Principles of Diagnosis DX-02*: Semmering, Austria, pp. 51-57, 2002.
- [23] A. L. Dulmage, N. S. Mendelsohn. “Two Algorithms for Bipartite Graphs” *Journal of the Society for Industrial and Applied Mathematics*: New Jersey, vol. 11(1), pp. 183-194, 1963.
- [24] R. Leal, J. Aguilar, E. Camargo, A. Ríos, “Modelo de Diagnosticabilidad para Procesos de Producción Petrolero”. *In Proceeding of the 5to Congreso*

-
- Iberoamericano de Estudiantes de Ingeniería Eléctrica (V CIBELEC 2012)*: pp. C17-C23, 2012.
- [25] M. Krysander. *Design and Analysis of Diagnostic Systems Utilizing Structural Methods*. PhD. Thesis, Linköpings University, Department of Electrical Engineering, Sweden, 2006.
- [26] J. Åslund and E. Frisk, “Structural analysis for fault diagnosis of models with constraints”, *In Proceedings of the 7th IFAC Symposium on Fault Detection Supervision and Safety of Technical Processes*: Barcelona, Spain, pp. 384-389, 2009.
- [27] M. Krysander, J. Åslund, and M. Nyberg, “An efficient algorithm for finding minimal over-constrained subsystems for model-based diagnosis”, *IEEE Transactions on Systems, Man, and Cybernetics Part A*: vol. 38(1), pp. 197-206, 2008.
- [28] O.G. Santos, S.N. Bordalo, F.J. Alhanati: “Study of the dynamics, optimization and selection of intermittent gas-lift methods a comprehensive model”, *Journal of Petroleum Science and Engineering*: London, vol. 32, pp. 231- 248, 2001.
- [29] G.O. Eikrem, B. Foss, L. Imrland, B. Hu, and M. Golan, "Stabilization of gas lift wells," *In Proceedings of the 15th IFAC World Congress*: Barcelona, Spain, 2002.
- [30] G.O. Eikrem, O.M. Aamo, H. Siahhan, B. Foss, “Anti-slug control of gas-lift wells - experimental results” *In Proceedings of the 6th IFAC Symposium on Nonlinear Control Systems*: Stuttgart, Germany, 2004.
- [31] E. Camargo, J Aguilar, A. Ríos, F. Rivas “Un modelo de producción de pozos por levantamiento artificial utilizando análisis nodal”. *Revista Ciencia e Ingeniería*: Bogotá, Colombia, vol. 30(1), pp. 23-28, 2009.

- [32] E. Camargo, J Aguilar, “Advanced Supervision of Oil Wells based on Soft Computing Techniques” *Journal of Artificial Intelligence and Soft Computing Research*: Warsaw, Poland, vol. 4(3), pp.215-225, 2015.
- [33] G. Hernández, E. Alí, T. Sharon, *Manual del curso de levantamiento artificial por gas avanzado*. 2^{da} ed. Los Teques, Venezuela: PDVSA Intevep, 2001.
- [34] B. Jansen, M. Dalsmo, L. Nskleberg, K. Havre, V. Knstiansen, and P. Lemetayer, "Automatic control of unstable gas lifted wells". *SPE paper no. 56832, presented at the SPE Annual Technical Conference and Exhibition*: Huston TX, 1999.
- [35] L. Imsland, *Topics in nonlinear control: Output feedback stabilization and control of positive systems*, Ph.D. Thesis, NTNU, Norwegian, 2002.
- [36] S. Ayatollahia, M. Narimania, M. Moshfeghian. “Intermittent gas lift in Aghajari oil field, a mathematical study”, *Journal of Petroleum Science and Engineering*: London, vol. 42, pp. 245-255, 2004.
- [37] M. Blanke, C. Frei, F. Kraus,R. Patton, and M. Staroswiecki, “What is fault tolerant control” *In Proceedings 4th IFAC Fault Detection, Supervision and Safety for Technical Processes-Safeprocess*: Budapest, Hungary, vol. 1, pp. 40-51, 2000.
- [38] M. Blanke, M. Kinnaert, J. Lunze, and M. Staroswiecki, *Diagnosis and fault tolerant control*, 2nd ed. Berlin, Germany: Springer, 2003.
- [39] V. Puig, J. Quevedo, T. Escobet, B. Morcego y C. Ocampo, “Control tolerante a fallos (Parte I): Fundamentos y diagnóstico de fallos”. *Revista Iberoamericana de Automática e Informática Industrial*: España, vol. 1(1), pp. 15-31, 2004.
- [40] E. Pérez, J. Acevedo, C. Fernández, J. Armesto, *Autómatas programables y sistemas de automatización*, 2^{da} ed. Vigo España: Marcombo, 2009.

- [41] J. Chen and R.J. Patton “Robust Model-Based Diagnosis for Dynamics Systems”. *International Journal of Robust and Nonlinear Control*: Boston, MA, vol. 11(14), pp 1400-1405, 1999.
- [42] R. Isermann and P. Ballé, “Trends in the application of model-based fault detection and diagnosis of technical processes”. *Control Engineering Practice*: vol. 5, pp. 709-719, 1997.
- [43] J. Aguilar, F. Rivas, *Introducción a las técnicas de computación inteligente*, Meritec, Merida, Venezuela, 2001.
- [44] D. E. Goldberg, Jr. R. Lingle “Alleles, loci and the traveling salesman problem”, *In Proceedings of the First International Conference on Genetic Algorithms and Their Applications*: Pittsburgh. PA, pp. 154-159, 1985.
- [45] J.D. Schaffer, R.A. Caruna, L.J. Eshelman, R. Das. “A study of control parameters affecting online performance of genetic algorithms for function optimization”, *In Proceedings of the Third International Conference on Genetic Algorithms, Morgan Kaufmann*: San Francisco, CA, pp. 51-60, 1989.
- [46] L. Davis, “Applying adaptive algorithms to episodic domains”, *In Proceedings of the International Joint Conference on Artificial Intelligence*: California, vol. 2 pp. 162-164, 1985.
- [47] H. Dale, *Production Optimization, Using NODALTM Analysis*. 2^{da} ed. Tulsa, OK: Oil & Gas Consultants International, 2003.
- [48] Z. Xu, M. Golan, “Criteria for operation stability of gas lift”, *SPE paper no. 19362*: Norwegian Institute of Technology, Norwegian, 1989.
- [49] Armengol, A. Bregon, T. Escobet, E. Gelso, M. Krysander, M. Nyberg, X. Olive, B. Pulido, and L. Travé-Massuyès. “Minimal structurally overdetermined sets for residual generation: A comparison of alternative approaches”, *In Proceedings of the 7th IFAC Symposium on Fault*: Barcelona, Spain, vol 2, pp. 1480-1485, 2009.

- [50] T. Villegas, *Aplicación de técnicas robustas para la detección y diagnóstico de fallos*, Tesis Doctoral, Universidad de Valladolid, España, 2012.
- [51] J. Gertler. "Generating Directional Residuals with Dynamic Parity Equations", *International Journal Automatica*, vol 31, pp. 627-635, 1995.
- [52] M. Staroswiecki, G. Comtet-Varga. "Analytical redundancy relations for fault detection and isolation Analytical redundancy relations for fault detection and isolation", *International Journal Automatica*, vol 37, pp. 687-699, 2001.
- [53] R. Leal, J. Aguilar, E. Camargo, A. Ríos, L. Travé, "Analysis of diagnosability for gas lift Wells", *Ingeniería y Ciencias Aplicadas: Modelos Matemáticos y computacionales (Ed. E. Dávila, J. Del Río, M. Cerrolaza, R. Chacón)*, Sociedad Venezolana de Métodos Numéricos en Ingeniería: Venezuela, pp. EC91-EC97, 2014
- [54] R. Leal, J. Aguilar, L. Trave-Massuyes, A. Ríos, E. Camargo."A Genetic Algorithm Approach for Diagnosability Analysis", *International Journal of Engineering Development and Research:India*, vol.2(4), pp. 3786-3799, 2014.
- [55] R. Leal, J. Aguilar, L. Travé-Massuyès, A. Ríos, E. Camargo. "An approach for diagnosability analysis and sensor placement for continuous processes based on evolutionary algorithms and analytical redundancy", *Applied Mathematical Sciences: Bulgaria*, vol. 9(43), pp. 2125 - 2146, 2015