

DONACION

Don. : TESIS

Exp. :

Inv N : 59940



Facultad de Ingeniería

UNIVERSIDAD NACIONAL DE RÍO CUARTO

TESIS DE MAESTRÍA EN INGENIERÍA QUÍMICA

*“LOCALIZACIÓN ÓPTIMA DE INSTRUMENTACION DE
PROCESOS”*

MERCEDES DEL CARMEN CARNERO

Río Cuarto

Argentina

2003

“Localización Óptima de Instrumentación de Procesos”

por

Mercedes del Carmen Carnero

Esta Tesis fue presentada para la obtención del título de
Magister en Ingeniería Química
y aprobada en su forma final según la reglamentación vigente de la
Escuela de Postgrado de la Universidad Nacional de Río Cuarto

<hr/> Director Prof. Dr. José Alberto Bandoni (UNS – PLAPIQUI)	<hr/> <i>Mabel Sánchez</i> Co-Director Prof. Dra. Mabel Sánchez (UNS – PLAPIQUI)
-----------------------------------------------------------------------------	--------------------------------------------------------------------------------------------------

Joaquín A. Orejas
Prof. Dr. Joaquín A. Orejas
Coordinador Maestría en Ingeniería Química - UNRC

Pedro Ducanto
Prof. Pedro Ducanto
Secretario Académico Facultad de Ingeniería - UNRC

Jurado de Tesis:

<hr/> <i>Osvaldo Alberto Agamenoni</i> Prof. Dr. Osvaldo Alberto Agamenoni	<hr/> <i>Omar Juan Alfredo Chiotti</i> Prof. Dr. Omar Juan Alfredo Chiotti
<hr/> <i>José Luis Figueroa</i> Prof. Dr. José Luis Figueroa	<hr/> <i>Mabel Sánchez</i> Prof. Dra. Mabel Sánchez

Río Cuarto, Junio de 2004

59940

REF:
Classf.:
T-351

Esta tesis se presenta como parte de los requisitos para la obtención del Grado Académico de Magister en Ingeniería Química de la Universidad Nacional de Río Cuarto. La misma, fue desarrollada bajo la dirección del Doctor Alberto Bandoni y la Doctora Mabel Sanchez, ambos Profesores de la Universidad Nacional del Sur y las actividades de investigación fueron realizadas en el Departamento de Ciencias Básicas de la Facultad de Ingeniería de la Universidad Nacional de Río Cuarto y dentro del marco de los siguientes proyectos de investigación: “ *Optimización Avanzada Aplicada a la Industria de Alimentos*”, dirigido por el Dr. Alberto Bandoni y “ *Optimización Discreta y Técnicas de Computación Evolutiva*”, dirigido por el Mgs. José Hernández, ambos subsidiados por la Secretaría de Ciencia y Técnica de la Universidad Nacional de Río Cuarto

Agradecimientos

Mi más sincero agradecimiento a todos aquellos que de una forma u otra hicieron posible la realización de este trabajo. A mis directores Alberto Bandoni y Mabel Sánchez por su invaluable guía y ayuda en la elaboración del mismo.

A la Secretaría de Ciencia y Técnica de la U.N.R.C y la Facultad de Ingeniería que brindaron los recursos necesarios para la ejecución del proyecto de investigación del cual formó parte esta tesis.

A mis compañeras de grupo y amigas María Ziletti, Alejandra Méndez y Marisa Pontín, por sus palabras de aliento y confianza.

A José Hernández, por su incondicional apoyo durante la escritura de esta tesis y su disposición a colaborar con las dificultades.

Por último, y especialmente, a mi familia, por su acompañamiento, su paciencia y ayuda a lo largo de todo este tiempo.

Resumen

En esta tesis se analiza el Diseño Óptimo de Redes de Sensores para el Monitoreo de Plantas de Proceso representadas por sistemas lineales. El desarrollo de estas estrategias resulta de interés con el fin de efectuar, en forma eficiente y automática, una asignación óptima de recursos económicos que asegure la disponibilidad y calidad de la información requerida del proceso.

Las estructuras de sensores se clasifican en redes: de número mínimo, redundantes y generales. Se examinan las diversas formulaciones existentes para su diseño, así como las metodologías y algoritmos de solución propuestos. Entre ellos, los Algoritmos Evolutivos (AE) muestran ventajas para resolver problemas de optimización combinatorios, cuyas características hacen necesaria la implementación de heurísticas capaces de proporcionar buenas soluciones en tiempos razonables.

Se estudia el Diseño Óptimo de Redes con Número Mínimo de Sensores para una variedad de criterios simples de desempeño, y se propone como estrategia de resolución un AE con operadores genéticos ad-hoc basados en conceptos del álgebra lineal, lo cual permite acotar el espacio de búsqueda del algoritmo sólo a la región factible. Dado que una de las aplicaciones de los AE de mayor actualidad se encuentra en el campo de la optimización multiobjetivo, se modifica la estrategia anterior con el objetivo de obtener soluciones Pareto-óptimas.

El Diseño Óptimo de Redes Generales de Sensores se aborda mediante un AE con población estructurada, obteniéndose buenos resultados en comparación con el enfoque památico.

Se incluyen ejemplos de aplicación de las estrategias propuestas a sistemas académicos y al sistema de vapor de una planta industrial.

Abstract

In this thesis the Optimal Sensor Network Design for the monitoring of process plants represented by linear systems, is presented. The development of these strategies is aimed at an efficient, automatic and optimum distribution of economic resources which ensure the availability and quality of the required information of the process.

The sensor structures are classified as following: minimum number sensor networks, redundant sensor networks and general sensor networks. The diverse existing formulations for their design as well as the methodology and algorithms proposed for their solution, are examined. The Evolutionary Algorithms (EA) are advantageous for solving combinatorial optimization problems, which make necessary the implementation of heuristics capable of providing solutions within reasonable time.

The Optimal Minimum Number Sensor Network Design for a set of single performance criteria, is examined and a resolution strategy that makes use of ad-hoc genetic operators based on linear algebra concepts is proposed. This makes feasible to limit the search space of the algorithm to a feasible region. Since one of these applications of the EA is in the area of multiobjective optimization, the latter strategy is extended in order to achieve Pareto-optimal solutions.

The Optimal General Sensor Network Design is approached within an EA with structured-population, which renders good results as compared to those of the panmitic approach.

Application examples are provided for the instrumentation design of academic systems and for an industrial steam metering network.

A Hugo, mi padre.
In memoriam

Índice

MARCO GENERAL	1
1.1 INTRODUCCIÓN	1
1.2 DISEÑO OPTIMO DE REDES DE SENSORES PARA MONITOREO	3
1.2.1 FORMULACIÓN GENERAL DEL PROBLEMA	3
1.2.2 MÉTODOS DE SOLUCIÓN EXISTENTES	4
1.2.2.1 Diseños basados en la utilización iterativa de un algoritmo de clasificación de variables 4	
1.2.2.2 Diseños óptimos utilizando algoritmos determinísticos	5
1.2.2.3 Diseños óptimos utilizando algoritmos estocásticos	6
1.3 OBJETIVOS DE LA TESIS	7
1.4 CONTENIDO DE LA TESIS	7
REVISIÓN BIBLIOGRÁFICA	9
2.1 INTRODUCCIÓN	9
2.2 REVISIÓN DE LAS METODOLOGÍAS EXISTENTES	9
2.2.1 RED DE SENSORES MÍNIMA	11
2.2.1.1 Sistemas Lineales	12
2.2.1.2 Sistemas bilineales	17
2.2.2 RED DE SENSORES REDUNDANTES	18
2.2.2.1 Sistemas Lineales	18
2.2.2.2 Sistemas Bilineales	20
2.2.3 RED DE SENSORES GENERAL	22
2.2.3.1 Sistemas Lineales	22
2.2.3.2 Sistemas Bilineales	25
2.3 CONCLUSIONES	26
NOMENCLATURA DEL CAPÍTULO II	28
APÉNDICE DEL CAPÍTULO II	30

ESTRATEGIAS EVOLUTIVAS EN PROBLEMAS DE OPTIMIZACION 34

3.1 INTRODUCCIÓN	34
3.2 DISEÑO OPTIMO DE REDES DE SENSORES	34
3.3 RESOLUCIÓN DEL PROBLEMA DE DISEÑO OPTIMO DE REDES DE SENSORES	36
3.4 ALGORITMOS EVOLUTIVOS	37
3.4.1 REPRESENTACIÓN GENÉTICA DE LAS SOLUCIONES	39
3.4.2 CREACIÓN DE LA POBLACIÓN INICIAL	39
3.4.3 FUNCIÓN DE EVALUACIÓN O FUNCIÓN DE ADAPTABILIDAD	40
3.4.4 OPERADORES GENÉTICOS	40
3.4.4.1 Operador de Selección	41
3.4.4.2 Operador de cruzamiento	43
3.4.4.3 Operador de Mutación	45
3.4.4.4 Elitismo	45
3.4.5 PARÁMETROS DE LOS ALGORITMOS EVOLUTIVOS	46
3.4.6 MANEJO DE LAS RESTRICCIONES	47
3.4.6.1 Estrategias de rechazo	47
3.4.6.2 Estrategias de Reparación	47
3.4.6.3 Estrategias de penalización	47
3.4.6.4 Modificación de los operadores genéticos:	48
3.5 CONCLUSIONES	48
NOMENCLATURA DEL CAPÍTULO III	50

DISEÑO DE REDES DE SENSORES MÍNIMAS 52

4.1 INTRODUCCIÓN	52
4.2 FORMULACIÓN GENERAL DEL PROBLEMA	52
4.3 EL ALGORITMO GOLOSO	53
4.3.1 LIMITACIONES DEL ALGORITMO GOLOSO	57
4.4 NUEVO ENFOQUE EVOLUTIVO PARA DISEÑO OPTIMO CON CRITERIO SIMPLE	59
a) Representación de la Solución	59
b) Determinación de la Población Inicial	59
c) Selección	61
d) Cruzamiento	61
e) Mutación	62

4.4.1 EJEMPLO DE APLICACIÓN	62
4.5 NUEVO ENFOQUE EVOLUTIVO PARA DISEÑO OPTIMO CON CRITERIOS MÚLTIPLES	64
4.5.1 OPTIMIZACIÓN MULTI OBJETIVO: SU RESOLUCIÓN MATEMÁTICA	64
4.5.2 DESCRIPCIÓN DE LA ESTRATEGIA PROPUESTA	70
4.5.3 EJEMPLO DE APLICACIÓN	71
4.6 CONCLUSIONES	73
NOMENCLATURA DEL CAPÍTULO IV	74
<u>DISEÑO DE REDES GENERALES DE SENSORES</u>	<u>76</u>
5.1 INTRODUCCIÓN	76
5.2 FORMULACIÓN DEL PROBLEMA	77
5.2.1 CLASIFICACIÓN DE VARIABLES MEDIANTE FACTORIZACIONES ORTOGONALES	78
5.2.2 CÁLCULO DE LAS RESTRICCIONES DE PRECISIÓN	81
5.3 NUEVO ALGORITMO EVOLUTIVO	81
5.3.1 JUSTIFICACIÓN DE UN ALGORITMO EVOLUTIVO CON POBLACIÓN ESTRUCTURADA	81
5.3.2 DISEÑO DEL ALGORITMO EVOLUTIVO	85
5.3.2.1 Generación de la Población Inicial	85
5.3.2.2 Función de aptitud	89
5.3.2.3 Operadores genéticos	89
a) Selección	89
b) Cruzamiento	92
c) Mutación	92
5.3.2.4 Procedimiento de búsqueda local	92
5.3.3 EJEMPLOS Y RESULTADOS	95
5.4 CONCLUSIONES	97
NOMENCLATURA DEL CAPÍTULO V	98
APÉNDICE CAPITULO V	100
<u>EJEMPLOS DE APLICACIÓN</u>	<u>102</u>
6.1 INTRODUCCIÓN	102
6.2 DESCRIPCIÓN DEL PROCESO	102
6.3 CASO 1	104
6.4 CASO 2	106

6.5 CASO 3	110
<u>CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS</u>	<u>121</u>
<u>REFERENCIAS BIBLIOGRÁFICAS</u>	<u>125</u>
<u>ANEXO: TRABAJOS PUBLICADOS Y PRESENTACIONES A CONGRESOS QUE SURGIERON DEL TRABAJO DE ESTA TESIS</u>	<u>132</u>

Índice de figuras

Figura 2.1. Clasificación de variables de proceso	10
Figura A2.1. Ejemplo de Grafo	30
Figura A2.2. Diagrama de flujo del proceso	30
Figura A2.3. Grafo del proceso	30
Figura A2.4. Spanning Tree para el grafo de la Figura A2.3	31
Figura. A2.5. <i>ST</i> obtenido por la inclusión de la cuerda 3 y la eliminación de la rama 1	33
Figura 3.1. Estructura de un AE simple	37
Figura 3.2 Operadores de cruzamiento	43
Figura 3.3 Operador de mutación	45
Figura 4.1. Diagrama de flujo para una planta de amoníaco	55
Figura 4.2 Frente pareto óptimo para el ejemplo de la planta de amoníaco	73
Figura 5.1. a) modelo panmítico; b) modelo de islas; c) modelo de vecindades	84
Figura 6.1. Diagrama de Flujo del Sistema de Vapor de la Planta de Producción de Metanol	104
Figura 6.2 Evolución del AE con 1000 generaciones	109
Figura 6.3 Evolución del AE	109
Figura 6.4. Comportamiento del AE para 100 experimentos	111
Figura 6.5. Evolución del AE para 100 generaciones	112
Figura 6.6. Comportamiento del AE panmítico para 100 ejecuciones	113
Figura 6.7. Evolución del AE panmítico para 100 generaciones	113
Figura 6.8. Evolución del AE	114
Figura 6.9. Distribución de los resultados obtenidos	114
Figura 6.10. Evolución del AE	116
Figura 6.11. Distribución de los resultados obtenidos	117
Figura 6.12. Evolución del AE	118
Figura 6.13. Distribución de los resultados obtenidos	114



Índice de tablas

Tabla 4.1. Datos para la planta de amoníaco	63
Tabla 4.2. Parámetros del AE	63
Tabla 4.3. Resultados de la optimización	64
Tabla 4.4. Parámetros del AE	72
Tabla 4.5. Conjunto pareto óptimo	72
Tabla 5.1. Población inicial para el ejemplo de la planta de amoníaco	90
Tabla 5.2 Individuos seleccionados como padres.	90
Tabla 5.3 Vecindades de cada individuo de la población seleccionada.	91
Tabla 5.4 Padres y madres seleccionados.	91
Tabla 5.5 Datos del ejemplo	96
Tabla 5.6 Parámetros del AE	96
Tabla 5. 7. Resultados de la optimización para el ejemplo propuesto	96
Tabla 6.1. Datos para el sistema de vapor de una planta de producción de metanol	103
Tabla 6.2 Parámetros para el AE.	105
Tabla 6.3. Resultados de la optimización	105
Tabla 6.4. Valores alcanzados por las diferentes funciones objetivo.	106
Tabla 6.5. Parámetros empleados por el algoritmo	106
Tabla 6.6. Conjunto de soluciones Pareto Óptimas	108
Tabla 6.7. Parámetros del AE	110
Tabla 6.8. Datos y Resultados del Diseño 1	110
Tabla 6.9. Datos y resultados del Diseño 2	114
Tabla 6.10. Datos y Resultados del Diseño 3	116
Tabla 6.11. Datos y Resultados del Diseño 4	118

CAPÍTULO I

MARCO GENERAL

1.1 Introducción

En la última década, la industria de procesos ha experimentado importantes desafíos comerciales, y en consecuencia cambios, que marcan la tendencia a producir bienes para un mercado globalizado y altamente competitivo, a la vez que se cumplen reglamentaciones ambientales y de seguridad más estrictas.

En respuesta a estos cambios, se han desarrollado nuevas estrategias, algunas de las cuales resultan habituales en la operación de las plantas químicas actuales. Cabe destacar entre éstas, la aplicación de la optimización en línea, el control estadístico de procesos, los sistemas de diagnóstico de fallas, el mantenimiento predictivo y basado en la confiabilidad.

Resulta evidente que la disponibilidad de información del proceso es indispensable para la ejecución de todas estas actividades. El grado de desarrollo alcanzado por los sistemas de monitoreo en línea y almacenamiento de datos permitieron disponer de un gran volumen de información de las plantas químicas. Por otra parte, la calidad del conocimiento adquirido, en lo relativo a su exactitud y precisión, mejoró notablemente gracias a la aplicación de procedimientos de Reconciliación de Datos.

En vista de los beneficios conseguidos con la utilización de información más exacta y precisa del proceso, tanto en el plano económico como en el de la seguridad y medio ambiente, es necesario dirigir ahora la atención hacia el origen de la información, es decir, *el conjunto de instrumentos instalados en la planta.*

El planeamiento de un Sistema de Instrumentación es una tarea compleja de múltiples niveles, que comprende la definición de los objetivos globales, la selección de

las variables medidas y la especificación de los detalles de implementación, tales como el intervalo entre mediciones, el método de toma de muestra, la interface con el operador, etc.

La información disponible del proceso depende esencialmente de la selección realizada en el segundo nivel, pues el grado de estimabilidad de las variables es función de la topología de la planta y de las observaciones realizadas.

En un proceso químico se pueden identificar varios miles de variables de estado, tales como: caudales, temperaturas, composiciones, presiones. Debido a causas económicas y de factibilidad técnica, sólo un subconjunto de ellas se mide. Se estima que el costo de instrumentación (incluyendo elementos de control) es del 2 al 8% del costo de capital fijo (Peters and Timmerhaus, 1980).

La selección del subconjunto de variables medidas, o Diseño de la Red de Sensores, se realiza durante la preparación del Diagrama de Proceso e Instrumentación. Es práctica común basar la decisión en la experiencia previa con plantas similares y en reglas empíricas, ya que no existen paquetes de cómputo que ayuden al diseñador en esta tarea. En consecuencia la disponibilidad de estrategias para efectuar la selección óptima de sensores resulta de sumo interés, ya que permitirá efectuar, en forma eficiente y automática, el diseño y/o actualización de Sistemas de Instrumentación. De esta manera se conseguirá una asignación óptima de los recursos económicos, que asegure la disponibilidad de la información requerida del proceso y niveles de seguridad aceptables.

El diseño óptimo de redes de sensores con fines de Control Regulatorio de Procesos (Seborg y co., 1989; Ogunnaike y Ray, 1994; Luyben y Floudas, 1994 a,b) y Análisis de Falla (Bhushan y Rengaswamy, 2002) se caracteriza por emplear modelos dinámicos, cuantitativos y cualitativos, correspondientes a la operación de un equipo o sectores de planta. Si el interés es lograr información más integral del proceso, a fin de monitorear variables relacionadas, por ejemplo, con la cuantificación de la producción, la calidad del producto, el desempeño operativo de equipos, la optimización en línea del proceso, el impacto sobre el medio ambiente, etc., la representación de su operación en

estado estacionario es la alternativa más adecuada. Esto se debe a que el tratamiento de datos de plantas complejas representadas por modelos dinámicos se encuentra en estado incipiente. Cabe aclarar que la presente tesis se focaliza en la localización óptima de sensores con el fin específico de monitorear observaciones y utilizar sus datos para estimar un conjunto de variables de interés.

1.2 Diseño Óptimo de Redes de Sensores para Monitoreo

1.2.1 Formulación General del Problema

La operación de una planta química puede representarse a través de un modelo matemático o conjunto de ecuaciones que relaciona las variables involucradas en el proceso. Dentro de estas últimas se distinguen dos subconjuntos: a) variables requeridas, o variables cuyo valor debe ser estimable; b) variables no requeridas.

El diseño de la red de sensores de una planta química con fines de monitoreo consiste en determinar para cada variable de proceso si será medida, y en tal caso, indicar cuántos sensores la medirán y cuáles son sus características (por ejemplo: costo, precisión, probabilidad de falla, etc.). El diseño debe garantizar la estimabilidad de las variables requeridas. A fin de obtener una distribución óptima de sensores, con respecto a algún criterio específico, se define el Diseño Óptimo de la Red de Sensores como un problema de optimización, cuya formulación general es la siguiente (Bagajewicz, 2000):

$$\begin{aligned} & \text{Min/Max } \mathbf{f}(\mathbf{q}) \\ & \text{st.} \\ & \mathbf{g}(\mathbf{q}) \leq \mathbf{g}^* \end{aligned} \tag{1.1}$$

siendo \mathbf{q} un vector de variables binarias tal que:

$$\begin{cases} q_i = 1, & \text{si la variable } i \text{ se mide} \\ q_i = 0 & \text{en caso contrario.} \end{cases}$$

Los criterios de desempeño, $\mathbf{f}(\mathbf{q})$, pueden ser diversos, por ejemplo: de tipo

económico, relacionados con la precisión de las estimaciones de las variables requeridas, o con la confiabilidad del sistema, etc. En cuanto al conjunto de las restricciones, $g(q)$, el diseño debe garantizar la estimabilidad de las variables requeridas, como así también las condiciones impuestas, por ejemplo, sobre su precisión, confiabilidad o disponibilidad.

En particular, en esta tesis se abordará el diseño de Sistemas de Instrumentación para Monitoreo de plantas químicas, cuya operación se describe mediante sistemas lineales en estado estacionario.

1.2.2 Métodos de Solución Existentes

Cualquiera sea la función objetivo y restricciones del problema (1.1), éste resulta un *problema de optimización combinatorial* con un número elevado de variables binarias, cuya solución depende fuertemente de sus características particulares. Los métodos de resolución existentes pueden asociarse a una de las tres categorías, que se presentan a continuación.

1.2.2.1 Diseños basados en la utilización iterativa de un algoritmo de clasificación de variables

La clasificación de variables no medidas y mediciones es una herramienta esencial en el diseño de sistemas de monitoreo. Los resultados de la clasificación permiten determinar:

- a) si la instrumentación propuesta es suficiente para conocer todas las variables claves del proceso, o sólo es posible estimar un subconjunto de ellas,
- b) si es factible corregir el valor de una medición para mejorar su precisión, etc.

El diseño de estructuras de sensores con ayuda de algoritmos de clasificación de variables se ha utilizado (Sánchez, 1996) para seleccionar:

- a) el número mínimo de instrumentos que aseguren la estimabilidad total o parcial de las variables no medidas del proceso
- b) el número mínimo de instrumentos que aseguren la estimabilidad de un conjunto de variables requeridas en función de mediciones redundantes.

Dado un conjunto inicial de instrumentos, la estrategia utilizada consiste en:

- a) clasificar las variables medidas y no medidas;
- b) modificar el conjunto de sensores, en base al juicio ingenieril del usuario;
- c) repetir a) y b) hasta satisfacer las condiciones de estimabilidad de las variables;
- d) eliminar sensores redundantes, si se excedió la cantidad mínima necesaria para satisfacer las condiciones de estimabilidad de las variables.

Si bien la solución encontrada es adecuada desde el punto de vista ingenieril, la convergencia al óptimo global no está garantizada. Además el método necesita la asistencia permanente del experto. El éxito depende de la calidad de la solución inicial propuesta, así como del tamaño del problema.

1.2.2.2 Diseños óptimos utilizando algoritmos determinísticos

En el caso particular que el problema implique la estimabilidad de todas las variables del proceso con la ubicación del número mínimo de instrumentos en sistemas lineales, y el criterio a optimizar sea el costo total de instrumentación, el problema resultante puede resolverse utilizando un algoritmo *goloso* (*algoritmo greedy*) que garantiza la obtención del óptimo global en tiempo polinomial (Papadimitriou y Steiglitz, 1982; Madron, 1992).

Para otro tipo de formulaciones no se han reportado métodos de resolución que garanticen la obtención del óptimo global para cualquier tamaño de una instancia en tiempo polinomial. En estos casos las posibles alternativas de solución son:

- a) algoritmos exponenciales, tales como el algoritmo de Branch and Bound, Branch and Cut y Programación Dinámica (Papadimitriou y Steiglitz, 1982; Nemhauser y Wolsey, 1999). Estas técnicas pueden ser aplicadas con éxito a instancias de tamaño razonable. Los algoritmos exponenciales aplicados hasta la actualidad son: 1) el procedimiento basado en la enumeración implícita con criterio de terminación propuesto por Bagajewicz (1997) y 2) la estrategia Branch and Bound aplicada para resolver problemas de optimización de tamaño pequeño con funciones objetivo lineales y restricciones convexificadas (Bagajewicz y Cabrera, 2001; Chmielewski y co., 2002).
- b) algoritmos de búsqueda local, basados en la búsqueda de óptimos locales en la vecindad de un punto. Los trabajos de Narasimhan y colaboradores están comprendidos en esta metodología (Narasimhan y Jordache, 2000).

1.2.2.3 Diseños óptimos utilizando algoritmos estocásticos

Desde el punto de vista de la teoría de optimización son métodos probabilísticos de orden cero, ya que sólo requieren los valores de la función a ser optimizada, y de búsqueda global. Pueden salir de un óptimo local dado que mantienen selectivamente un conjunto de soluciones de menor desempeño que la actual, las cuales pueden evolucionar hacia el óptimo global.

Las desventajas residen en que dada su naturaleza estocástica no ofrecen ninguna garantía de convergencia para una corrida dada, y además el costo computacional puede ser elevado; aunque esta última característica se supera sustancialmente incorporando conocimiento específico del problema a resolver.

Las estrategias de localización óptima de sensores encontradas en la literatura son procedimientos evolutivos basados en Algoritmos Genéticos (AG) (Sen y co., 1998), que se aplican al caso de redes con un número de sensores establecido previamente, característica que los hace restrictivos a casos particulares de diseño.

1.3 Objetivos de la Tesis

La motivación de esta tesis está basada en las limitaciones encontradas para resolver problemas de Diseño Óptimo de Redes de Sensores con funciones objetivo y restricciones complejas, correspondientes a plantas de tamaño considerable. Estas limitaciones provienen fundamentalmente de la naturaleza combinatoria del problema que resulta en la imposibilidad de contar con algoritmos de tiempo polinomial para los casos de interés práctico.

En consecuencia, los objetivos de esta tesis son desarrollar e implementar estrategias de Diseño Óptimo de Redes de Sensores para el Monitoreo de plantas, representadas por sistemas lineales, aplicables a diferentes funciones objetivo y con restricciones impuestas sobre la estimabilidad de un conjunto de variables requeridas, y además, sobre la precisión y/o confiabilidad de sus estimaciones. Los procedimientos de cálculo son estrategias evolutivas basadas en AG. Se ha seleccionado dicho tipo de procedimiento por su buen desempeño para la resolución de problemas que involucran decisiones sobre la estructura y la secuencia de procesos en Ingeniería Química.

1.4 Contenido de la Tesis

En el Capítulo 2 se presenta una revisión crítica de las metodologías existentes para resolver, en forma automática, el problema de diseño óptimo de instrumentación.

La complejidad matemática asociada a la resolución de la localización óptima de estructuras de sensores se discute en el Capítulo 3. El mismo contiene los conceptos básicos relacionados con la aplicación de Algoritmos Evolutivos (AE), basados en AG, para resolver problemas de optimización.

El diseño de una red de sensores que asegure la estimabilidad de todas las variables, con el mínimo número de instrumentos, se aborda en el Capítulo 4. En él se analizan las características de las diferentes formulaciones obtenidas al cambiar la función objetivo y se desarrolla un nuevo método evolutivo de solución. Además se incluye la adaptación de esta estrategia con el fin de resolver problemas de optimización multiobjetivo.

El diseño de arreglos de instrumentos con restricciones sobre un subconjunto de variables requeridas se presenta en el Capítulo 5. La nueva estrategia de selección óptima permite satisfacer diferentes restricciones de diseño, entre ellas las de estimabilidad y precisión sobre un conjunto de variables requeridas.

El Capítulo 6 contiene ejemplos de diseño de redes de sensores para el sistema de vapor de una planta de producción de metanol. Las conclusiones y futuras líneas de investigación se presentan en el Capítulo 7.

CAPÍTULO II

REVISIÓN BIBLIOGRÁFICA

2.1 Introducción

En las plantas químicas modernas resulta imprescindible conocer los valores de diferentes variables y parámetros del proceso con determinada precisión y confiabilidad, a fin de realizar tareas de diagnóstico de la operación, control y optimización.

Afortunadamente no es necesario efectuar la medición directa de cada una de las incógnitas (variables requeridas o claves), lo cual sería una práctica irrealizable para alguna de ellas. Si se miden un subconjunto de variables seleccionadas estratégicamente, las restantes pueden calcularse utilizando los balances de masa y energía.

En ciertas aplicaciones existen diferentes configuraciones de sensores cuya localización permite satisfacer el grado de conocimiento requerido del proceso. En tal caso, se pretende encontrar la configuración óptima de sensores que satisface uno o varios criterios, tales como: el costo total de instrumentación, el error global de estimación, la confiabilidad del sistema, etc. La determinación del conjunto óptimo de instrumentos se conoce como Diseño Óptimo de Redes de Sensores.

En este capítulo se incluye una revisión del estado actual del conocimiento en este tema. Posteriormente se presentan las conclusiones de la revisión bibliográfica que determinaron los objetivos que condujeron la investigación.

2.2 Revisión de las metodologías existentes

El problema de ubicación de sensores en plantas químicas está estrechamente asociado al de la clasificación de las variables de un proceso.

Dada una planta que opera en estado estacionario, sus variables están relacionadas fundamentalmente por las leyes de conservación de masa y energía. Por

razones de costo, conveniencia o factibilidad técnica no se miden todas las variables del proceso. No obstante, algunas variables no medidas pueden ser estimadas utilizando los valores de las mediciones mediante la resolución de ecuaciones de balance de masa total, por componentes, balances de energía, etc.. La posibilidad de estimar las variables no medidas depende fundamentalmente de la estructura del diagrama de flujo del proceso y de la ubicación de los instrumentos. Normalmente se dispone de un conjunto incompleto de mediciones, de modo que las variables no medidas se clasifican en *observables* y *no observables*. Las primeras se pueden estimar por cálculos a partir de los valores de las mediciones. En cuanto a las mediciones, éstas se dividen en *redundantes* y *no redundantes*. Una medición es redundante, si en caso de no efectuarse dicha medición la variable resulta determinable. La Figura 2.1 esquematiza la categorización de variables.

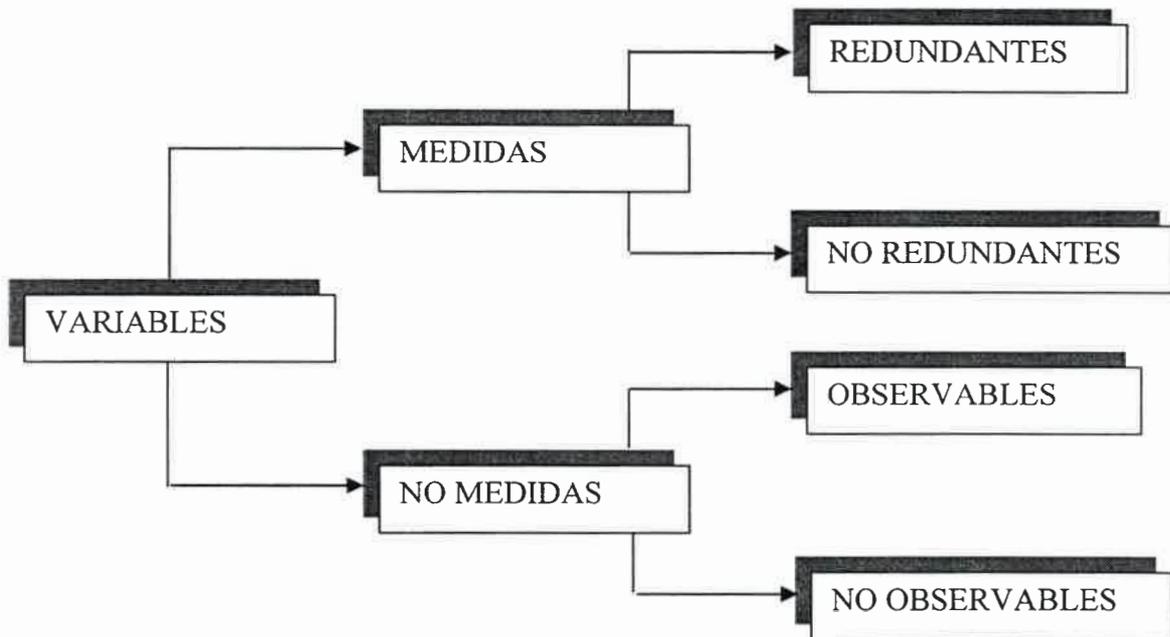


Figura 2.1. Clasificación de variables de proceso

En la literatura se presentan diferentes algoritmos de clasificación de variables, algunos se basan en la teoría de grafos y otros están orientados al uso de ecuaciones (Mah, 1990; Madron, 1992; Romagnoli y Sánchez, 1999; Narasimhan y Jordache, 2000).

El Diseño de Instrumentación asistido con algoritmos de clasificación de variables para procesos cuya operación se describe mediante un sistema de ecuaciones algebraicas es un proceso iterativo. Dado un conjunto inicial de sensores, el diseñador aplica la estrategia de clasificación de variables a fin de determinar si las variables requeridas son estimables. Si esta condición se satisface, se procede luego a verificar el cumplimiento de otras restricciones, por ejemplo de precisión o confiabilidad. Si resulta necesario modificar el conjunto de instrumentos, el diseñador decide la incorporación y/o eliminación de sensores en base a su conocimiento del proceso y juicio ingenieril. Las etapas de clasificación de variables, análisis de los resultados de la clasificación y modificación del conjunto de sensores se repiten secuencialmente hasta completar la selección de los instrumentos que permiten conocer toda la información deseada del proceso. Cabe destacar que este procedimiento no involucra la optimización de criterios de tipo económico en forma explícita, aunque se tiende a reducir la cantidad de instrumentos instalados.

Hacia fines de la década del 80 aparecen los primeros trabajos de Diseño Optimo de Sensores, con fines diferentes a los de control y análisis de fallas. A fin de sintetizar los aportes de diferentes investigadores en la resolución de este problema de optimización, se categorizan las redes de sensores en tres clases y se analizan las metodologías utilizadas hasta el presente para abordar el diseño de cada clase. Esta división se realiza porque, como se indicó en el capítulo previo, la resolución de los problemas de optimización resultantes es muy dependiente de la funcionalidad del criterio de optimización y de las restricciones con respecto a las variables binarias.

2.2.1 Red de Sensores Mínima

Una Red de Sensores Mínima está formada por el menor número de sensores que permite calcular todas las variables no medidas del proceso. Esta definición tiene varias implicancias:

- a) el número de sensores es igual al número de grados de libertad del sistema de m ecuaciones y n variables que modela el proceso, por lo tanto es un dato del problema.

- b) todas las variables medidas son no redundantes, ya que se utilizan para calcular las no medidas y no hay disponibles ecuaciones adicionales para corregir las mediciones.
- c) todas las variables no medidas son observables.

Las metodologías de resolución también se clasifican dependiendo de la complejidad del modelo utilizado para describir la operación de la planta en:

- a) lineales: si se consideran sólo los balances de masa,
- b) bilineales: si se consideran los balances de masa por componentes o balances simplificados de energía, donde la entalpía específica de la corriente se describe como función exclusiva de la temperatura.

2.2.1.1 Sistemas Lineales

El problema de diseño óptimo de redes de caudalímetros que verifican la estimabilidad de todas las variables no medidas es el más difundido en la literatura. Las estrategias de resolución se dividen en dos grandes grupos, las que aplican la teoría de grafos y las que se basan en los conceptos del álgebra lineal.

Metodologías orientadas a los grafos

Los grafos han sido ampliamente utilizados para analizar problemas que involucran objetos discretos y sus interrelaciones. Dado que la localización de sensores en plantas químicas se encuadra dentro de esta problemática, existen numerosas estrategias de resolución basadas en la teoría de grafos. Por tal motivo se incluyen algunos de sus conceptos fundamentales en el Apéndice del presente capítulo. Las correspondientes demostraciones están disponibles en libros de texto (Chen, 1971; Even, 1979).

Nota: En esta revisión bibliográfica los términos *spanning tree (ST)*, *cutset (Cu)* y *fundamental cutset (FCu)* provenientes del idioma inglés serán utilizados sin traducción al idioma castellano, tal como es la práctica usual.

Vaclavek (1969) y Mah y co. (1976) iniciaron la aplicación de los conceptos de la teoría de grafos para la clasificación de las variables intervinientes en los balances de masa total. Mah y co. (1976) demostraron que la condición necesaria y suficiente para que todos los caudales no medidos sean estimables es que no existan ciclos en el grafo del proceso que contengan exclusivamente caudales no medidos. En cuanto a las mediciones, éstas son redundantes si participan en ciclos en los cuales al menos dos variables son medidas.

Posteriormente Madron (1992) remarcó que la estimabilidad de todas las variables no medidas utilizando el menor número de sensores podía asociarse a la existencia de un subgrafo acíclico conteniendo la mayor cantidad de variables no medidas. Dado que cada *ST* del grafo conecta todos los nodos con el menor número de ramas, una red de sensores mínima puede diseñarse construyendo un *ST* y eligiendo las cuerdas del grafo como variables medidas.

A fin de minimizar el costo total de instrumentación (*CT*) Madron propuso una estrategia basada en la búsqueda del *ST* de máximo costo. Asoció a cada arista el costo del instrumento asignado para medir el correspondiente caudal. A partir de la arista de mayor costo, formó un árbol mediante la sucesiva incorporación de aristas, en orden decreciente de costo, que no formaran ciclos con las anteriores. Así obtuvo el *ST* asociado a los caudales no medidos y a los instrumentos de mayor costo; los de menor costo se ubican en las cuerdas de este *ST*, que están relacionadas con las variables medidas. Este procedimiento permite obtener el óptimo global del problema planteado.

Madron definió el desvío estándar promedio, σ_s , de un sistema de instrumentación como:

$$\sigma_s = \left[\sum_{i=1}^n \hat{\sigma}_i^2 / n \right]^{1/2} \quad (2.1)$$

siendo n el número de variables de proceso y $\hat{\sigma}_i^2$ la varianza de la estimación de la variable i . Analizó la selección óptima de puntos de medición que minimicen la función (2.1). La no linealidad de la función objetivo hace inviable la aplicación de la estrategia usada para minimizar el CT . Para obtener una solución subóptima del problema propuso una estrategia que consiste en obtener el ST de máximo desvío estándar y luego generar STs de distancia uno, o sea aquellos que difieren en una arista respecto del original. Cuando un nuevo ST tiene una función objetivo mejor que el original, éste se considera como el ST inicial y se repite el procedimiento hasta que no se encuentra una mejor solución a una distancia unitaria del ST en análisis.

Narasimhan y sus colaboradores desarrollaron una estrategia general para el diseño de redes de sensores lineales mínimas. El procedimiento utiliza como dato un ST cualquiera del grafo del proceso e iterativamente genera nuevos STs que son mejores en términos del criterio de optimización elegido para el diseño, es decir se efectúa una búsqueda inteligente. El nuevo ST generado en cada iteración se obtiene a partir del anterior intercambiando una de las ramas por una de las cuerdas. Esta técnica se conoce como transformación elemental de árbol. Es decir, un sensor se ubica en una de las ramas y se elimina de una de las cuerdas, a fin de mantener la estructura tipo ST de la red de sensores. La nueva solución puede considerarse como un vecino inmediato de la solución previa y en consecuencia la estrategia se encuadra dentro del grupo de búsquedas locales en la vecindad, que en la mayoría de los casos dan soluciones localmente óptimas.

Ali y Narasimhan (1993) introdujeron el concepto de confiabilidad de estimación de una variable (R_V), al que definieron como la probabilidad de estimar una variable, medida o no medida, para una dada red de sensores que pueden fallar en forma independiente con probabilidades de falla conocidas. Estos autores propusieron una estrategia para maximizar la menor confiabilidad de estimación del conjunto formado por todas las variables, a la que denominaron confiabilidad de la red. Dado un ST del grafo del proceso, el procedimiento busca cuál es la variable no medida de menor confiabilidad. Esta resulta la rama, b_r correspondiente a los $FCus$ de mayor cardinalidad (es decir de mayor número de elementos), asociados al ST . Sea $Fcu_r \oplus Fcu_s$ la suma

anillo entre Fcu_r (Fcu del ST que contiene a b_r) y Fcu_s (Fcu del ST que contiene a b_s), la confiabilidad de la red aumenta colocando un sensor sobre la rama b_s y eliminándolo de la cuerda c_p , si se satisfacen las siguientes condiciones:

- a) $c_p \in Fcu_s$ y $c_p \in Fcu_r$;
- b) la cardinalidad de $Fcu_r \oplus Fcu_s$ es menor que la cardinalidad de Fcu_r , es decir $|Fcu_r \oplus Fcu_s| < |Fcu_r|$;
- c) si $c_p \in Fcu_j$, para cualquier Fcu entonces, $|Fcu_j \oplus Fcu_s| < |Fcu_r|$;
- d) todos los sensores tienen la misma probabilidad de falla.

La variable b_s se considera como saliente y la c_p como entrante. Si las probabilidades de falla de los sensores son distintas, en lugar de evaluar la cardinalidad de la suma anillo en las condiciones b) y c) se calcula la confiabilidad de las variables b_s y b_j .

Si no es posible encontrar una variable entrante y otra saliente que satisfagan las tres condiciones, esto no implica que se ha obtenido un óptimo global. Además si las desigualdades no son estrictas o si hay dos o más variables con la misma confiabilidad mínima, es posible obtener soluciones sucesivas que no mejoran la confiabilidad de la red. Estos problemas fueron abordados mediante el uso de heurísticas, tales como una selección aleatoria de las cuerdas y el procedimiento de escalada (“hill climbing”).

La estrategia general de Narasimhan fue aplicada por Bansal y co. (1994) con el fin de minimizar el error global de estimación de las variables (GE), definido por Kretsovalis y Mah (1987) como la suma de las varianzas de las estimaciones de las variables

$$GE = \sum_{i=1}^n \hat{\sigma}_i^2 \quad (2.2)$$

Para el caso de redes de sensores mínimas, se demostró que esta función objetivo resulta igual a la suma, sobre todas las cuerdas del ST , del producto entre el número de ocurrencias de la cuerda en los $Fcus$, Oc_i , incrementado en una unidad y la varianza del

instrumento utilizado para medir la variable.

$$GE = \sum_{i=1}^{n-m} (Oc_i + 1) \sigma_i^2 \quad (2.3)$$

Sobre la base de la ecuación (2.3) se desarrollaron reglas para seleccionar las variables entrantes y salientes. Las cuerdas se ordenan en orden decreciente de su contribución $Oc_i \sigma_i^2$ a la función objetivo y se eligen en ese orden como candidatos a variables entrantes. Una vez que se ha seleccionado la cuerda, cualquiera de las ramas del circuito fundamental de la cuerda puede seleccionarse como variable de salida. Estas se ordenan en orden creciente de los desvíos estándar de los correspondientes instrumentos y se eligen en ese orden. Si un conjunto de variables de entrada y salida reduce el GE , entonces se ha obtenido una nueva solución y el procedimiento se repite. En caso contrario se elige el siguiente candidato a variable saliente. Si el conjunto de variables salientes está vacío, se elige el siguiente candidato a variable entrante. El algoritmo finaliza cuando no hay más combinaciones de variables entrante/saliente que produzcan una reducción de GE .

Sen y co. (1998) desarrollaron una estrategia para el diseño óptimo de redes mínimas aplicable para optimizar cualquier criterio. El método sigue el esquema de los AG y utiliza conceptos de la teoría de grafos a fin de codificar la solución y diseñar operadores genéticos que mejoren la eficiencia del AG clásico. Cada diseño de la red de sensores se codifica con un conjunto de enteros que representan las cuerdas del correspondiente ST . Los operadores de cruzamiento y mutación se basan en efectuar transformaciones elementales de árbol, que producen ST factibles.

Metodologías basadas en el álgebra lineal

Los balances de masa total de un proceso que opera en estado estacionario pueden representarse por el siguiente modelo lineal:

$$\mathbf{Dz} = \mathbf{Ax} + \mathbf{Bu} = \mathbf{0} \quad (2.4)$$

siendo \mathbf{D} la matriz de incidencia de dimensión $(m \times n)$, \mathbf{z} $(n \times 1)$ es el vector de caudales másicos totales, \mathbf{x} representa el vector de variables medidas y \mathbf{u} el de no medidas; \mathbf{A} y \mathbf{B} son submatrices de dimensión compatible. La estimabilidad de todas las variables no medidas con el menor número de sensores implica medir $g = (n-m)$ caudales totales. En consecuencia la submatriz \mathbf{A} debe tener dimensión $(m \times g)$ y \mathbf{B} debe ser una submatriz cuadrada de dimensión $(m \times m)$.

Maquin y co. (1987) enunciaron que el menor costo de una red lineal mínima se obtenía aislando la matriz \mathbf{B} no singular tal que la suma de los costos de los instrumentos asociados a sus columnas fuera máxima. Estos autores no propusieron ningún procedimiento de resolución.

2.2.1.2 Sistemas bilineales

Metodologías orientadas a los grafos

Ali y Narasimhan (1996) presentaron una estrategia para resolver el problema del diseño óptimo de redes de sensores mínimas constituídas por caudalímetros y termocuplas y/o sensores de composición. El objetivo de la optimización, como en trabajos previos, consistió en maximizar la mínima confiabilidad de estimación entre todas las variables.

Este trabajo constituye un aporte preliminar tendiente a la resolución de un problema complejo. El método presenta las siguientes limitaciones: a) en una corriente están presentes todos los componentes del proceso en concentraciones no nulas; b) no se permite una medición parcial de las composiciones de una corriente; c) un solo sensor se utiliza para medir todas las composiciones de una corriente; d) la cantidad de caudales medidos permite la estimación de todos los caudales no medidos. Las tres primeras limitaciones son de relevancia para los procesos con multicomponentes, mientras que la última es una limitación teórica importante, dado que impide utilizar mediciones de caudal y composición ó caudal y temperatura para calcular los caudales no medidos.

Como se mencionó en la sección anterior, la observabilidad de los caudales no medidos se asegura si éstos forman un ST en el grafo del proceso, al que indicamos como ST^f . Esto surge porque los flujos másicos son estimados exclusivamente utilizando la lectura de los caudalímetros. Para que se verifique la observabilidad de las composiciones no medidas (estimadas en función de los caudales medidos y observables y las composiciones medidas), éstas también deben formar un ST en el grafo del proceso, que indicamos como ST^c . El procedimiento de solución actualiza iterativamente los ST denominados ST^f y ST^c mediante la estrategia desarrollada por Ali y Narasimhan (1993) para el caso lineal.

2.2.2 Red de Sensores Redundantes

Una red de sensores redundantes es aquella formada por una cantidad de instrumentos superior a la necesaria para conseguir una estimación única de todas las variables. Esta situación presenta varias ventajas: a) la corrección de las variables medidas redundantes mediante estrategias de Reconciliación de Datos, b) la detección e identificación de los errores gruesos, c) la posibilidad de disponer de la estimación de algunas variables en caso de fallas de sensores.

Las metodologías de resolución se clasifican dependiendo de la complejidad de los modelos en lineales y bilineales.

2.2.2.1 Sistemas Lineales

Metodologías orientadas a los grafos

Ali y Narasimhan (1995) abordaron el diseño de una red de caudalímetros, con un número fijo de sensores mayor que el mínimo, con el objetivo de maximizar la menor confiabilidad en la estimación de una variable.

El algoritmo se inicializa definiendo un conjunto de mediciones e iterativamente se mejora la solución. El procedimiento determina cuál es la variable con la menor confiabilidad de estimación e identifica los $FCUs$ que la contienen. De éstos se elige una

nueva variable medida y se elimina una de las existentes, si el cambio produce un incremento en el valor de la confiabilidad. En cada iteración se busca mejorar la solución actual en su vecindad, ya que las soluciones difieren en un sensor. Por lo tanto es un clásico método de búsqueda local.

Metodologías basadas en el álgebra lineal

Kretsovalis y Mah (1987) cuantificaron el efecto de introducir y eliminar mediciones en la red sobre la precisión de las estimaciones obtenidas mediante el procedimiento de Reconciliación de Datos. Utilizando estas relaciones desarrollaron una estrategia combinatoria para agregar un número fijo de sensores a una red inicial de instrumentos, que ya permitían la observabilidad de todas las variables no medidas.

El criterio de selección para incorporar un sensor k a la red consiste en minimizar la suma pesada Ψ_k entre el error de estimación y el costo, según indica la siguiente fórmula

$$\Psi_k = a c_{ki} + (GE_0 + \Delta GE_{ki}) \quad (2.5)$$

donde, c_{ki} es el costo asociado a la instalación del sensor k en la posición disponible i , GE_0 es una medida del error de estimación correspondiente a la estructura original y ΔGE_{ki} corresponde a la variación del error ocasionado por la localización del nuevo instrumento k en la posición i , a es un factor de peso positivo.

La ubicación de K nuevos instrumentos se realiza explorando todas las combinaciones de localizaciones factibles para los instrumentos y seleccionando la combinación con la menor función objetivo.

La estrategia de Ragot y co. (1992) permite considerar restricciones en la ubicación de sensores. Dado que se parte de un proceso con instrumentación inicial, normalmente resulta una red de sensores redundante. La matriz de incidencia del proceso, que representa los balances de masa de las unidades, se separa en columnas

correspondientes a las variables medidas (\mathbf{A}) y las no medidas medibles (\mathbf{B}_m) y no medibles ($\mathbf{B}_{\bar{m}}$). Mediante sucesivas transformaciones matriciales se obtiene la forma canónica de \mathbf{B}_m y $\mathbf{B}_{\bar{m}}$. Se seleccionan nuevas mediciones asociadas a las variables no contenidas en la parte regular de \mathbf{B}_m . Con la incorporación de estos sensores y si $\mathbf{B}_{\bar{m}}$ coincide con la matriz identidad, el sistema resultante es completamente observable.

La estrategia previa fue extendida por Heraud y Mazzour (1999) con el fin de minimizar el costo de los nuevos instrumentos. El método se basa en reacomodar la porción de la matriz de incidencia correspondiente a las variables no medidas \mathbf{B} , en orden decreciente de costo, asumiendo un costo infinito para aquellas variables que no pueden medirse debido a cuestiones técnicas. Se buscan pivotes en las columnas de la matriz reordenada y los términos no-nulos de las columnas con pivotes se eliminan por adición o sustracción de filas. Las columnas con pivotes son permutadas a fin de formar la matriz identidad que permite calcular las correspondientes variables no medidas. Las restantes variables deben medirse, siendo el costo de instrumentación mínimo.

2.2.2.2 Sistemas Bilineales

Tanto Ragot y co. (1992) como Heraud y Mazzour (1999) extendieron sus estrategias basadas en el álgebra lineal con el fin de diseñar sistemas de monitoreo para procesos representados por sistemas de ecuaciones lineales y bilineales. Los balances de masa total asociados a los balances de multicomponentes se encuentran en esta categoría. Este enfoque sólo considera la medición de la composición de todos los componentes de la corriente o de ninguno de ellos, esto permite analizar el sistema bilineal como una sucesión de dos sistemas lineales. A ambos sistemas se les asocia la matriz de incidencia del proceso, pero las columnas del primero (\mathbf{D}_1) representan los caudales másicos totales mientras que las del segundo (\mathbf{D}_2) están asociadas a la composición.

En primer término Ragot y co. propusieron reglas de localización de sensores en sistemas bilineales basados en los resultados de la clasificación de las variables intervinientes en sistemas elementales que involucran una ecuación lineal y la correspondiente bilineal. Las reglas son las siguientes:

- a) Si el sistema elemental presenta dos caudales no medidos y una composición no medida, es posible ejecutar dos acciones: i) medir un caudal, calcular el restante del balance de masa, calcular la composición del balance de componentes; ii) medir la composición, calcular los dos caudales mediante la resolución simultánea del sistema elemental.
- b) Si el sistema elemental presenta todos los caudales conocidos y dos composiciones no medidas: medir una composición y calcular la restante.
- c) Si el sistema elemental presenta tres caudales no medidos y todas las composiciones conocidas: medir un caudal y calcular los dos caudales restantes mediante la resolución simultánea del sistema elemental.

En base a estas reglas desarrollaron una estrategia de diseño iterativa que comprende las siguientes etapas:

- a) Análisis de observabilidad con la instrumentación inicial, aplicando el método de categorización de variables de sistemas bilineales elementales.
- b) Descomposición de las matrices asociadas a los caudales y composiciones, D_1 y D_2 , según las columnas correspondientes a las variables medidas, no medidas medibles y no medibles, $[A_1, B_{1m}, B_{1\bar{m}}]$ y $[A_2, B_{2m}, B_{2\bar{m}}]$. Análisis simultáneo de ambas matrices con el fin de localizar nuevos sensores en base a las reglas de diseño propuestas. La ubicación de un nuevo instrumento conduce a aplicar nuevamente la etapa a.

A fin de minimizar el costo de instrumentación Heraud y Mazzour (1999) ordenaron las submatrices correspondientes a las variables no medidas B_1 y B_2 en orden decreciente de costo y las reemplazaron por su forma canónica, siguiendo la metodología del caso lineal. Luego aplicaron una estrategia de localización de sensores que consta de las siguientes etapas:

- a) Medición de todas las variables de \mathbf{B}_2 , cuyas columnas no contienen pivotes y tal que el número máximo de variables no medidas por ecuación resulte 0 (la ecuación es redundante) ó 1 (la ecuación es de cálculo). Esta regla surge porque las composiciones sólo pueden calcularse de balances de componentes.
- b) Medición de todas las variables de \mathbf{B}_1 , cuyas columnas no contienen pivotes y tal que el número de variables no medidas (caudales) por ecuación sea superior a 2. El número máximo de variables no medidas por ecuación resulta 2 ó 1 (si la ecuación es de cálculo) ó 0 (si la ecuación es de reconciliación).
- c) Si algunas variables son no observables, se seleccionan secuencialmente como medidas las variables de menor costo en \mathbf{B}_1 o \mathbf{B}_2 que modifiquen la observabilidad.

2.2.3 Red de Sensores General

Una red de sensores general está formada por un número de instrumentos desconocido de antemano, que surge de optimizar la condición de desempeño de la red, sujeta a restricciones asociadas con un conjunto de variables claves. A diferencia de las redes de sensores mínima y redundante, la observabilidad de *todas* las variables no medidas no es condición necesaria.

Existen diferentes estrategias de resolución dependiendo de la complejidad matemática del modelo del proceso.

2.2.3.1 Sistemas Lineales

Metodologías orientadas a los grafos

Luong y co. (1994) desarrollaron una estrategia de localización de sensores que permite la estimación única de un conjunto de variables requeridas R , y a la vez

disponer de la estimación para un subconjunto $R_1 \subset R$ aún en el caso de falla de j sensores, con el mínimo costo de instrumentación. El método aplica los conceptos enunciados por Mah y co. (1976) para la categorización de las variables intervinientes en sistemas lineales mediante el análisis de los ciclos del grafo del proceso, Cys . El algoritmo comprende tres etapas:

- a) formulación de la matriz de los Cys que contienen al menos una variable requerida.
- b) formación de todos los posibles conjuntos de nuevas mediciones que producirían una estimación única de las variables contenidas en R y selección de la alternativa de menor costo. Para ello se necesita medir al menos una variable por cada Cy que contenga variables pertenecientes a R .
- c) formación de todos los posibles conjuntos de nuevas mediciones que aseguren la estimación de las variables contenidas en R_1 aún si fallan j sensores y selección de la alternativa de menor costo, considerando como instalados los sensores seleccionados en b). Esto se consigue midiendo al menos $(j+1)$ variables por ciclo que contenga variables en R_1 .

Los Cys también fueron utilizados por Meyer y co. (1994) para analizar la estimabilidad de un conjunto de variables requeridas, como parte de un procedimiento de diseño de sistemas de monitoreo de mínimo costo, para plantas representadas por balances lineales. Se consigue la solución óptima mediante un método tipo Branch and Bound. El límite inferior de la rama, luego de la inclusión de j sensores en la red, es la suma del costo de instrumentación para el nivel j del árbol de búsqueda más el costo del instrumento más barato que podría incorporarse a cada ciclo fundamental del grafo, para conseguir la observabilidad de las variables requeridas. El límite superior es el costo de la primera solución encontrada y su valor se actualiza durante el procedimiento.

Metodologías basadas en el álgebra lineal

Dentro de las metodologías para diseño de redes de sensores generales, el trabajo pionero para sistemas lineales corresponde a Madron y Veverka (1992). Estos autores propusieron dos funciones objetivos: el costo de instrumentación y el desvío estándar promedio de las estimaciones de las variables requeridas, calculadas aplicando procedimientos de reconciliación de datos.

El método propone dividir la matriz de ocurrencia del proceso considerando las variables no medidas y medidas, separadas en requeridas y no requeridas. Además se ordenan las variables no medidas en orden creciente de factibilidad técnica y económica de medición, idea utilizada por otros autores posteriormente tales como Ragot y co. (1992) y Heraud y Mazzour (1999), y aplicar un procedimiento de eliminación de Gauss-Jordan sobre la matriz ordenada. Si el análisis de la matriz resultante indica que no todas las variables requeridas son medidas u observables, se seleccionan nuevos sensores correspondientes a las variables más fáciles de medir. Los autores demostraron que la solución es óptima, considerando al costo como función objetivo, si no existen variables no observables no requeridas. En caso contrario no puede asegurarse la optimalidad de la solución, aunque ésta resulta una buena solución práctica.

Más reciente es el trabajo de Chmiesewski y co. (2002), donde el problema de diseño de redes de sensores se formula como un problema de optimización no lineal mezcla entera (MINLP), en el cual se asocia un sensor a todas las variables del proceso. Una variable es no medida, si la varianza del sensor localizado sobre dicha corriente tiene un valor muy grande. La función objetivo es el costo de capital, con restricciones sobre diferentes indicadores de desempeño, tales como la precisión de las estimaciones, la capacidad de detección de errores gruesos y la probabilidad que la precisión de las estimaciones esté acotada para redes de sensores con probabilidades de falla fijas. Las restricciones no lineales son convertidas a restricciones de desigualdad convexas, las cuales toman la forma de desigualdades matriciales lineales. Esta conversión se sustenta en la linealidad existente entre las variables de decisión binarias y la inversa de la matriz de covarianza asociada a las mediciones. La técnica de resolución es un algoritmo Branch and Bound donde en cada nodo se resuelve un subproblema con las restricciones

enteras relajadas y dada la convexificación de éstas, se garantiza que las soluciones encontradas constituyen óptimos globales.

Un enfoque similar es el adoptado por Bagajewicz y Cabrera (2001) para desarrollar un modelo Mezcla Entera Lineal (MILP) para la optimización del costo asociado a una red de sensores con restricciones. En la construcción del modelo también se considera que todas las variables son medidas, ya sea con instrumentos reales o ficticios de alto desvío estándar, y que se dispone de varios instrumentos como candidatos para la medición de una corriente. El modelo puede ser extendido al caso en que exista redundancia originada por la localización de instrumentos del mismo tipo en una corriente. Las restricciones no lineales se convierten en lineales utilizando una transformación debida a Glover (1975), con lo cual el problema MINLP original se transforma en un MILP, que es resuelto utilizando el algoritmo GAMS (Brooke y co., 1992).

2.2.3.2 Sistemas Bilineales

Vaclavek y Loucka (1976) iniciaron el uso de la clasificación de las variables contenidas en balances de masa y multicomponentes como herramienta para diseñar una red de sensores que satisficiera la observabilidad de un conjunto de variables requeridas. Utilizaron un programa de clasificación de variables en sistemas bilineales, basado en la teoría de grafos. El procedimiento de localización de sensores se inicia categorizando las variables en medibles (conjunto A) y no medibles (conjunto B), dependiendo de la factibilidad técnica de los métodos de medición, y en requeridas (conjunto R) y no requeridas (conjunto D). El objetivo es definir un conjunto de mediciones tal que todas las variables requeridas sean medidas o no medidas observables.

En el primer paso de la estrategia se efectúa la clasificación de variables luego de considerar como medidas todas las variables medibles. Se obtienen los conjuntos A_1 , A_2 , B_1 y B_2 , correspondientes a las mediciones redundantes, no redundantes, variables no medidas observables y no observables respectivamente. Si se verifica la condición $B_2 \cap R = \emptyset$, el segundo paso consiste en clasificar un conjunto de mediciones formado

por todas las variables medibles y las observables requeridas ($B_1 \cap R$). De la clasificación se obtiene un conjunto de variables redundantes (E) y no redundantes (F). Las variables que deben medirse para asegurar la estimabilidad de las requeridas están contenidas en los siguientes conjuntos: $F_1 = F \cap R$ y $E_2 = A_2 \cap E$; F_1 comprende las variables medibles requeridas no redundantes y E_2 contiene las variables medibles utilizadas para estimar las no medidas observables requeridas.

2.3 Conclusiones

Del análisis de la literatura citada surge que existen diferentes formulaciones para el diseño de redes de sensores, y que la estrategia de resolución a utilizar para el problema de optimización, depende fuertemente tanto del criterio a optimizar como del conjunto de restricciones impuesto.

En el diseño de redes de sensores mínimas sin restricciones para sistemas lineales se presentan dos casos. Si la función objetivo es lineal es posible utilizar algoritmos de resolución que garantizan la obtención del óptimo global en tiempo polinomial para instancias del problema de cualquier tamaño. En caso contrario, las técnicas propuestas permiten hallar soluciones subóptimas. El diseño de sistemas bilineales se ha resuelto sólo en forma aproximada utilizando iterativamente los algoritmos desarrollados para sistemas lineales.

La resolución del diseño de redes de sensores redundantes verifica las mismas conclusiones enunciadas en el párrafo anterior.

El caso de mayor interés industrial corresponde al diseño de redes de sensores generales, con funciones objetivo complejas y restricciones no lineales. El problema se ha formulado como uno del tipo MINLP. Asociado a éste existen dos principales dificultades, la primera relacionada con la naturaleza combinatorial del mismo y la segunda con la complejidad de las relaciones funcionales entre las variables.

A medida que el número de variables binarias crece, el tiempo de ejecución del algoritmo se incrementa exponencialmente, ya que del análisis de complejidad

computacional surge que los problemas MINLP se caracterizan como NP-completos (Floudas, 1995), ésto es no se conocen algoritmos polinomiales para encontrar su solución, por lo tanto sólo instancias de tamaño pequeño pueden resolverse. Al mismo tiempo la no linealidad de estos problemas puede ser no convexa.

Para instancias del problema de tamaño pequeño y funciones bien comportadas, una técnica de Branch and Bound más relajación de las variables binarias en cada nodo puede ser utilizada con éxito. Más aún, la implementación de este algoritmo sólo requiere que el conjunto solución en cada nodo pueda particionarse en dos subconjuntos mutuamente excluyentes y disponer de un algoritmo para el cálculo de un límite inferior de la función objetivo para cualquier solución en un conjunto dado. Por lo tanto, de verificarse estas condiciones, es una forma de solución aplicable a cualquier tipo de función objetivo y conjunto de restricciones.

Cuando el número de posibles ubicaciones de los instrumentos aumenta, el costo computacional asociado a estas técnicas se incrementa de tal forma, que se vuelven impracticables. En estos casos la utilización de estrategias basadas en heurísticas aparecen como una alternativa válida, ya que si bien carecen de garantías formales sobre su desempeño, son útiles para hallar “buenas” soluciones a problemas que representan escenarios más realistas.

Una heurística ampliamente utilizada para resolver problemas de optimización combinatorios son los AE, cuyos principales lineamientos se describen en el capítulo siguiente, y han sido seleccionados como método de resolución del problema de diseño óptimo de sensores, por los motivos enunciados previamente.

Nomenclatura del Capítulo II

a	Factor de peso
A	Matriz de variables medidas
b	Rama de un Spanning Tree
B	Matriz de variables no medidas
B_m	Submatriz de variables no medidas medibles
$B_{\bar{m}}$	Submatriz de variables no medidas no medibles
c	Cuerda de un Spanning Tree
c_{ki}	Costo asociado a la instalación del sensor k en la posición i
CT	Costo total de instrumentación
C_u	Cutset del grafo del proceso
C_y	Ciclo del grafo del proceso
D	Matriz de incidencia del proceso
F_{cu}	Cutset fundamental del grafo del proceso
FC_y	Ciclo fundamental del grafo del proceso
g	Número de Mediciones en Redes de Sensores Mínimas
GE	Error global de estimación
K	Número de sensores extras incorporados a una red mínima
m	Número de ecuaciones del modelo del proceso
n	Número de variables del modelo del proceso
O_{c_i}	Número de ocurrencias de la cuerda c_i en los FCus del ST
R	Conjunto de variables requeridas
R_1	Subconjunto de variables requeridas en presencia de fallas de sensores
R_Y	Confiabilidad de estimación de una variable
ST	Spanning tree
ST^f	ST de caudales para modelos de proceso bilineales
ST^c	ST de composiciones para modelos de proceso bilineales
T	Conjunto de aristas del grafo
u	Vector de variables no medidas
V	Conjunto de nodos del grafo
x	Vector de variables medidas

- z Vector de caudales máxicos totales
Letras Griegas
- σ_s Desvio estándar promedio de un sistema de instrumentación
- $\hat{\sigma}_i^2$ Varianza en la estimación de la variable i
- Ψ Suma ponderada entre el error de estimación y el costo

APÉNDICE DEL CAPÍTULO II

Conceptos Fundamentales de la Teoría de Grafos

Un grafo consta de un conjunto de *nodos*, \mathbf{V} , y de un conjunto de *aristas*, \mathbf{T} . Cada arista está asociada o es *incidente* al par de nodos que une. Un ejemplo de un grafo se muestra en la Figura A2.1, éste tiene seis nodos dibujados como círculos y ocho aristas representadas como líneas.

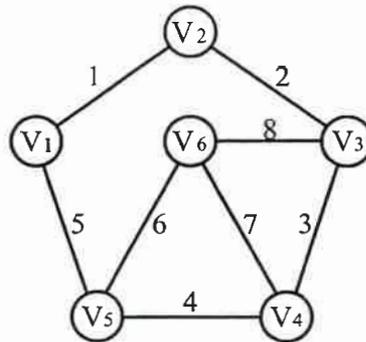


Figura A2.1. Ejemplo de Grafo

El grafo de un proceso es un grafo obtenido a partir del diagrama de flujo del proceso en consideración, agregándole un nodo que representa el *medio ambiente*. Este nodo extra se conecta con todas las corrientes de alimentación y productos del proceso. En la Figura A2.2 se representa el diagrama de flujo simplificado de una planta de producción de amoníaco, cuyo grafo de proceso corresponde al de la Figura A2.3.

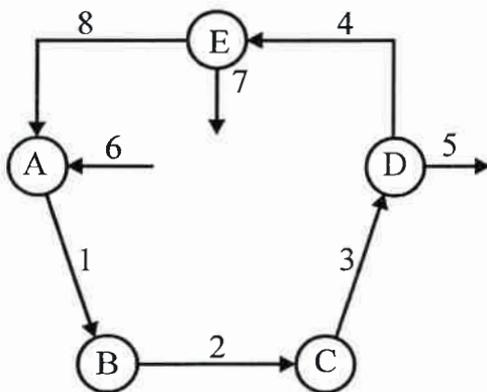


Figura A2.2. Diagrama de flujo del proceso

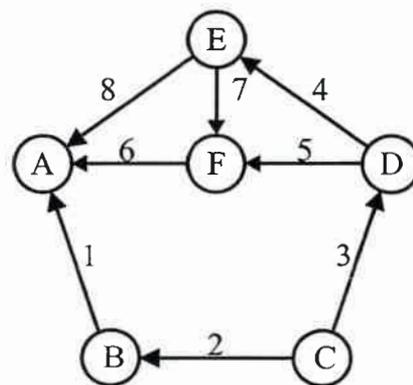


Figura A2.3. Grafo del proceso

Si las direcciones de las corrientes son irrelevantes se obtiene un *grafo no dirigido*; en caso contrario el grafo es *dirigido*. Un *subgrafo* de un grafo consta de un subconjunto de nodos y aristas del grafo.

Un *camino* entre dos nodos es una secuencia finita en la cual se alternan nodos y aristas, tal que cada arista en la secuencia es incidente al nodo precedente y sucesor y además ningún nodo aparece más de una vez en la secuencia. Un camino se denomina *ciclo* si el nodo inicial coincide con el final. Por ejemplo en la Figura A2.3 la secuencia de las aristas 1-2-3, junto con los nodos extremos de cada arista, es un camino, mientras que 1-2-3-5-6, junto con los nodos extremos de cada arista, es un ciclo. El grafo es conectado si existe un camino entre cada par de nodos del grafo.

Se denomina *spanning tree (ST)* a un subgrafo conectado de un grafo que no contiene ciclos e incluye todos los nodos del grafo. Una arista del grafo que forma parte del *ST* se conoce como *rama*, mientras que una arista del grafo que no participa de éste se denomina *cuerda*. La clasificación de las aristas en ramas y cuerdas depende del *ST* seleccionado. En la Figura A2.4 se representa un *ST* del grafo de la Figura A2.3. Las aristas 1, 2, 4, 5, y 8 se categorizan como ramas y las aristas 3, 6 y 7 son las cuerdas. Se ha probado (Deo, 1974) que un *ST* contiene m ramas y $(n - m)$ cuerdas, siendo m el número de unidades del proceso y n el número de corrientes o aristas del grafo.

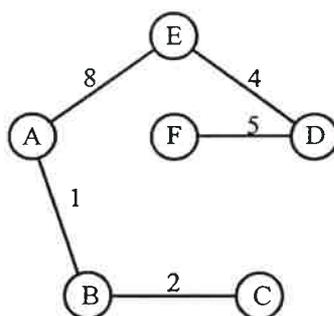


Figura A2.4. Spanning Tree para el grafo de la Figura A2.3

Un *conjunto de corte* o *cutset (Cu)* es un conjunto de aristas del grafo cuya eliminación desconecta el grafo. El conjunto de aristas (1, 4, 5) es un *Cu* del grafo

representado en la Figura A2.3. La eliminación de estas aristas desconecta el grafo en dos conjuntos de nodos: (A, E, F) y (B, C, D). Es necesario aclarar que el conjunto de aristas (1, 3, 4, 5) no es un Cu , dado que el Cu (1, 4, 5) está incluido en él. La suma anillo entre dos Cus se indica como $Cu_1 \oplus Cu_2$ y es el conjunto de todas las aristas contenidas en Cu_1 y Cu_2 pero no en ambos.

Un *conjunto de corte fundamental* o *fundamental cutset* (FCu) de un ST es un Cu del grafo que contiene una sola rama del ST y cero ó más cuerdas. Los $FCus$ correspondientes al ST de la Figura A2.4, correspondiente al grafo de la Figura A2.3, son: (2, 3), (1, 3), (8, 3, 6), (4, 3, 6, 7) y (5, 6, 7). La rama correspondiente a cada FCu se ha indicado en primer lugar en los conjuntos anteriores.

Un concepto complementario al anterior es el de *ciclo fundamental* o *fundamental cycle* (FCy) con respecto a un dado ST . Un FCy es un ciclo del grafo (Cy) formado exactamente por una cuerda y una ó más ramas de un ST del grafo. El ciclo 3-1-2-4-8 es un FCy del grafo de la Figura A2.3 con respecto al ST de la Figura A2.4 ya que consta de la cuerda 3 y las ramas 1, 2, 4 y 8. Para cada cuerda de un ST de un grafo se puede identificar un FCy . Para el ejemplo que nos ocupa todos los $FCys$ son (3, 1, 2, 4, 8), (6, 4, 5, 8) y (7, 4, 5). La cuerda correspondiente a cada FCy se ha ubicado en primer lugar en los conjuntos anteriores.

Los $FCus$ son complementarios de los $FCys$ dado que si una cuerda c_p participa en el FCu de una rama b_r entonces, la rama b_r participa del FCy de la cuerda c_p . Esta propiedad se aplica para identificar los $FCys$ con respecto a un ST dados los $FCus$ con respecto al mismo ST .

Dado un ST de un grafo es posible generar otros ST del mismo grafo mediante una técnica denominada Transformación Elemental de Arbol. Esta consiste en agregar una cuerda al ST original y eliminar una rama perteneciente al FCy de la cuerda incorporada. Por ejemplo el ST mostrado en la Figura A2.5 es un nuevo ST del grafo de la Figura A2.3 obtenido a partir del ST de la Figura A2.4 por adición de la cuerda 3 y eliminación de la rama 1 que pertenece al ciclo fundamental de la cuerda 3.

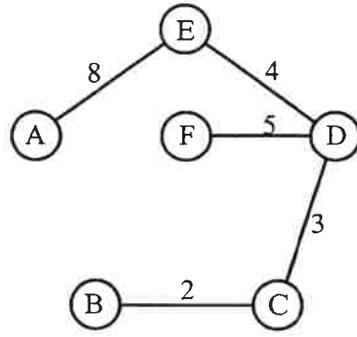


Figura. A2.5. *ST* obtenido por la inclusión de la cuerda 3 y la eliminación de la rama 1

CAPÍTULO III

ESTRATEGIAS EVOLUTIVAS EN PROBLEMAS DE OPTIMIZACION

3.1 Introducción

Desde el punto de vista de las variables involucradas, los problemas de optimización pueden dividirse en forma muy general en dos categorías: aquellos con variables continuas, y aquellos con variables discretas, llamados problemas combinatorios. En los primeros la atención se centra en un conjunto de números reales o de funciones; en los segundos, la atención está puesta en un objeto de un conjunto finito o infinito contable, tal como un entero, una permutación, una combinación o un grafo. Estas dos clases de problemas tienen características diferentes, y los métodos de resolución aplicados a ellos resultan muy disímiles. Los problemas de diseño de redes de sensores pertenecen a la segunda categoría.

En este capítulo se categoriza el diseño de redes de sensores como un problema de optimización combinatorial y se presentan los aspectos básicos de los AE basados en AG seleccionados para su resolución.

3.2 Diseño Óptimo de Redes de Sensores

Una instancia de un problema de optimización es un par (G, f) , donde G es el conjunto de puntos factibles y f la función de desempeño ó función objetivo, tal que:

$$f: G \rightarrow R^l \quad (3.1)$$

El problema es encontrar un $g^* \in G$ para el cual:

$$f(g^*) \leq f(g), \quad \forall g \in G. \quad (3.2)$$

El punto g^* es llamado un óptimo global. Un *problema de optimización* consta de un conjunto I de instancias todas generadas en forma similar. Informalmente, en una



instancia se dispone de los “datos de entrada” y suficiente información como para obtener una solución.

En relación con el diseño óptimo de redes de sensores, si representamos con \mathbf{x} el vector de variables medidas y con \mathbf{u} el vector de variables no medidas, una vez fijado \mathbf{x} queda determinado \mathbf{u} , y en consecuencia una configuración particular para la red de sensores. Esta configuración de hecho no es única. Si $A=\{1, 2, \dots, n\}$ es el conjunto finito de índices de todas las variables involucradas, y P contiene todas las combinaciones posibles de elementos de A , entonces existe una relación biunívoca entre cada elemento de P y un vector de variables medidas \mathbf{x} . El número total de combinaciones de mediciones posibles es el cardinal de P , $|P| = 2^n$.

De acuerdo a los requisitos (restricciones) que se impongan al diseño, sólo un subconjunto de P tiene asociado vectores de mediciones factibles. Estas restricciones están relacionadas con el grado y la calidad de conocimiento deseado del proceso, por ejemplo, el subconjunto de variables cuyo valor es necesario conocer y la precisión asociada a ellas.

La función de desempeño o función objetivo, f , puede estar dada por la suma de los costos de los instrumentos, la suma de las exactitudes asociadas a todas las variables, la productoria de las confiabilidades para un tiempo t de cada variable, etc. De forma general puede decirse entonces que, el problema de localización óptima de instrumentación consiste en encontrar la configuración de costo mínimo que satisfaga las restricciones impuestas.

La dicotomía asociada al evento de medir cada variable de proceso se modela utilizando una variable binaria q_i tal que, $q_i=1$ si la variable se mide ó $q_i=0$ en caso contrario. Por lo tanto a cada elemento de P , se le puede asignar un vector n -dimensional de variables binarias, \mathbf{q} , tal que cada elemento q_i en \mathbf{q} verifica la definición anterior. En consecuencia, el conjunto factible G se considera formado por puntos ubicados en los vértices de un hiperespacio unitario $\in R^n$, cada uno de ellos con costo $f(\mathbf{q})$.

Debido a la naturaleza combinatorial del problema, la cardinalidad del espacio factible aumenta significativamente con el número de variables n , resultando un problema de Optimización Discreta de difícil solución.

3.3 Resolución del Problema de Diseño Óptimo de Redes de Sensores

Se dice que un algoritmo resuelve eficientemente un problema, si puede ser aplicado para resolver *cualquier* instancia del problema y se garantiza que siempre produce una solución para la instancia. Si el criterio de eficiencia seleccionado es la rapidez del algoritmo, la solución debería obtenerse en un tiempo razonable.

De acuerdo a Garey (1999), es conveniente expresar el tiempo de ejecución de un algoritmo en términos de una sola variable, el tamaño de la entrada del problema, E . Se entiende como tal la cantidad de símbolos, pertenecientes a un alfabeto finito, necesarios para especificar la entrada.

Se define la función de complejidad de un algoritmo, C , como el mayor tiempo necesario para resolver una instancia de un tamaño determinado. Tal función no es generalmente conocida ni determinable fácilmente, pero proporciona un criterio para distinguir los algoritmos eficientes de los no eficientes. Se dice que un algoritmo es eficiente si su función de complejidad está acotada por un polinomio y es ineficiente en caso contrario. Esto da origen a la clasificación de algoritmos en:

- a) Algoritmos de tiempo polinomial. Aquellos cuya función de complejidad cumple la siguiente condición, $|C(E)| \leq a |p(E)|$ para todo $E > 0$, siendo a una constante y $p(E)$ un polinomio de grado E .
- b) Algoritmos de tiempo exponencial: aquellos cuya función de complejidad no está acotada por un polinomio de grado E .

El diseño óptimo de redes de sensores involucra funciones objetivo y restricciones tales que, para los casos de mayor interés práctico, no se han reportado métodos de resolución que garanticen la obtención del óptimo global para cualquier

tamaño de una instancia. Como se mencionó en el Capítulo 1, los métodos existentes son de tipo determinístico (Algoritmos Exponenciales y de Búsqueda Local) y estocásticos. En esta tesis se utilizará como estrategia de resolución un AE, dado que éstos permiten obtener buenas soluciones en tiempos de ejecución razonables para problemas de diseño complejos.

3.4 Algoritmos Evolutivos

Los AE son procedimientos estocásticos que mantienen una población de individuos $P(t) = \{x'_1, \dots, x'_N\}$ para cada iteración t . Cada individuo constituye una solución potencial del problema a tratar, la cual se representa mediante una estructura de datos S . La solución x'_i se evalúa utilizando una medida de su aptitud. Luego se forma una nueva población (iteración $t+1$) seleccionando los mejores individuos de $P(t)$. Algunos miembros de la nueva población sufren transformaciones unarias m_i (mutación), que crean un nuevo individuo a partir de sí mismo ($m_i: S \rightarrow S$) y transformaciones de orden más alto c_j (tipo cruzamiento) que crean nuevos individuos combinando partes de algunos (dos o más) individuos ($c_j: S \times S \dots \times S \rightarrow S$). El algoritmo se ejecuta un cierto número de generaciones ó hasta que se satisface algún criterio de detención. En la Figura 3.1 se muestra la estructura de un AE simple.

```
* AE simple.
t=0;
iniciar P(t);
hacer_mientras(no condición de detención)
    t=t+1;
    selección (P(t)) desde P(t-1);
    cruzamiento(P(t));
    mutación(P(t));
fin_de_hacer
fin
```

Figura 3.1. Estructura de un AE simple

Dentro de estos AE se encuentran los AG puros. Es una práctica común en la literatura sobre el tema reservar el nombre de AG para la técnica evolutiva desarrollada

por Holland (Holland, 1975), aunque no existe una línea divisoria bien clara entre estos algoritmos y otros inspirados en los mismos principios (Michalewicz, 1996).

Durante los últimos años los AE están siendo utilizados en la resolución de diversos problemas de optimización combinatorial con restricciones, tales como el problema del viajante (TSP), el problema de coloreo de un grafo, el empaçado de objetos, la búsqueda de un ciclo hamiltoniano, problemas de diseño en ingeniería (Schütz, 2000), la resolución de problemas de programación no lineal mezcla entera (Costa, 2001), etc; entre otros.

Está generalmente aceptado que cualquier AE debe tener cinco componentes básicos (Michalewicz, 1996):

- a) Una representación genética de las soluciones.
- b) Una forma de crear una población inicial de soluciones.
- c) Una función de evaluación que "ordena" las soluciones en términos de su adaptabilidad o *fitness*.
- d) Operadores genéticos que alteran la composición genética de los hijos durante la reproducción.
- e) Valores de los parámetros que gobiernan la evolución (tamaño de la población, probabilidad de aplicar los operadores genéticos, etc).

También es conocido que para lograr una implementación exitosa de una técnica evolutiva en un problema concreto, los componentes básicos listados arriba requieren de heurísticas adicionales.

3.4.1 Representación genética de las soluciones

Para diseñar un AE es necesario codificar una solución del espacio de búsqueda real en una solución del espacio de búsqueda del AE, denominada cromosoma. Esto implica una transformación entre ambos espacios de tal forma que la codificación no admita duplicación de soluciones.

En uno de los primeros trabajos sobre AG, debido a Holland (Holland, 1975), la codificación se realiza utilizando cadenas binarias de longitud fija. Cada elemento de la cadena se denomina bit. Mientras que las variables binarias son naturalmente representadas mediante un código de este tipo, las variables continuas deben ser representadas utilizando un determinado número de bits asociado al grado de precisión requerido.

Sin embargo, dependiendo del problema particular a resolver, ésta puede no ser la forma de codificación más efectiva. De hecho se han propuesto representaciones mediante vectores de números reales para problemas de optimización numérica multidimensionales y con altos requerimientos de precisión, obteniéndose mejores resultados que aquellos alcanzados con la representación binaria tradicional (Wright, 1991).

Por otro parte, en ciertos problemas de optimización combinatoria, una alternativa puede ser codificar una solución utilizando un vector de números enteros. Por ejemplo en el problema del TSP, se han utilizado diferentes tipos de representaciones: por adyacencia, ordinal y por caminos, cada una de las cuales viene dada por un vector entero que codifica un camino determinado (Michalewicz, 1996).

3.4.2 Creación de la población inicial

Con respecto a este punto se disponen de varias heurísticas. Se puede comenzar con una población generada en forma aleatoria (como en un AG clásico), lo cual implica la existencia de individuos no válidos, o en el otro extremo usar la salida de algún algoritmo determinístico para inicializarla.

En ciertos problemas de localización de sensores, es posible contar con algún conocimiento sobre la forma de la solución. Por ejemplo, determinadas corrientes deben ser medidas ya que existe instrumentación disponible en esos puntos ó a la inversa, ciertas variables necesariamente deben ser calculadas a través de las ecuaciones que rigen el proceso. Para aprovechar esta información, una porción de la población inicial se forma teniendo en cuenta estas sub-combinaciones. Es necesario determinar qué porcentaje de la población recibe ese conocimiento a priori de la solución para evitar conducir al AG a una convergencia temprana.

3.4.3 Función de evaluación o función de adaptabilidad

En los métodos de computación evolutiva la función de evaluación sirve no sólo como nexo entre el problema y el algoritmo, sino que mide la calidad de las soluciones. En base a las diferencias en calidad, los mejores individuos de la población tienen mejores posibilidades de supervivencia y reproducción. Por lo tanto es esencial definir una función de adaptabilidad que caracterice al problema de un modo adecuado.

En la mayoría de los casos, el proceso de selección de una función de adaptabilidad parece ser directo, sin embargo tal proceso puede resultar más complejo cuando trabajamos con soluciones factibles y no factibles. A menudo la población contiene individuos no factibles, pero se busca un *óptimo factible*. Encontrar una medida de adaptabilidad para ambos tipos de individuos es de gran importancia, ya que influye directamente en el resultado del algoritmo. Las diferentes estrategias desarrolladas para manejar poblaciones que contienen individuos infactibles se presentarán posteriormente en este capítulo.

3.4.4 Operadores genéticos

Como se puede apreciar en la Figura 3.1, el algoritmo hace evolucionar sucesivas generaciones de individuos hasta obtener la solución óptima. La creación de una nueva población utilizando los operadores genéticos es un punto muy importante e involucra a los operadores de selección, cruzamiento y mutación.

3.4.4.1 Operador de Selección

Durante la selección la población es sometida a un muestreo estocástico para obtener el conjunto de individuos sobre los cuales se aplicarán los operadores de mutación y cruzamiento. En los AE la selección juega un rol muy importante, dado que imprime una dirección sobre el proceso de búsqueda, basada en dar preferencia a aquellos individuos de mejor aptitud. Es el único componente del AE donde el fitness del individuo tiene impacto sobre el proceso evolutivo.

De forma ideal, la selección debería asegurar una amplia exploración del espacio de búsqueda al comienzo del AE (presión selectiva baja), mientras que en las etapas finales sería deseable una explotación marcada de las regiones más promisorias (presión selectiva alta). Este conflicto entre exploración versus explotación, ha dado origen a varios métodos de selección de individuos de una población para su supervivencia y reproducción. Estos se caracterizan en términos de la *probabilidad de selección* como sigue (Back, 1996): selección proporcional, métodos de ranking y selección por torneo.

La selección proporcional (Goldberg, 1989) es una estrategia donde la probabilidad de ser padres es proporcional al fitness de cada individuo. Si la población tiene N individuos, cada uno con un fitness F_i , entonces la probabilidad, p_s , de que un cromosoma cr_i sea seleccionado estará dada por

$$p_s(cr_i) = \frac{F_i}{FT} \quad (3.3)$$

donde

$$FT = \sum_{i=1}^N F_i \quad (3.4)$$

El inconveniente de la selección proporcional es que en las primeras generaciones del AE los valores de adaptabilidad promedio son pobres. La presencia de individuos con un valor de fitness bueno provoca que el mecanismo de selección proporcional asigne un número grande de copias a estos superindividuos, provocando así la convergencia temprana.

Con el objetivo de mitigar estos problemas se han propuesto mecanismos tales como el escalado y la selección por ranking. El primero de ellos asocia a cada valor de la función objetivo un número real positivo (fitness escalado) y determina la probabilidad de supervivencia de un individuo de acuerdo a este valor. La forma funcional de esta asignación determina diferentes tipos de escalado tales como: escalado lineal, escalado logarítmico y truncamiento sigma. Presenta como desventaja que debe elegirse cuál es el tipo de escalado más conveniente y determinar los nuevos parámetros asociados al mismo.

El método de selección por ranking, propuesto originalmente por Baker (Baker, 1985) consiste en ordenar la población en orden decreciente de fitness y asignar la probabilidad de selección de cada cromosoma de acuerdo a su rango, sin tener en cuenta el valor de su fitness original. En el ranking lineal, la probabilidad de selección asignada a los individuos es proporcional al rango k de los mismos, el mejor individuo tiene rango 1 y el peor rango N

$$p_s(cr_i) = \frac{1}{N} \left[\eta_{m\acute{a}x} - 2(\eta_{m\acute{a}x} - 1) \frac{k-1}{N-1} \right] \quad (3.5)$$

El parámetro $\eta_{m\acute{a}x}$ representa el número esperado de veces que el mejor individuo será seleccionado. Teniendo en cuenta que $\sum_{i=1}^N p_s(cr_i) = 1$, puede demostrarse que $1 \leq \eta_{m\acute{a}x} \leq 2$. Por lo tanto la elección de un valor particular de $\eta_{m\acute{a}x}$ sirve para controlar la presión selectiva.

Otra alternativa es la selección por torneo (Bickle y Thiele, 1996), en la cual un individuo necesita ganar una competencia entre un conjunto de individuos seleccionados aleatoriamente. En un torneo de tamaño C_o , el mejor de C_o individuos es seleccionado en forma determinística, ésto es gana el mejor adaptado, aunque ocasionalmente puede ser utilizada una selección estocástica.

3.4.4.2 Operador de cruzamiento

En los AE los individuos de una población $P(t)$ generan descendencia transmitiéndole sus características genéticas a sus hijos. Para transformar la población se aplica inicialmente el operador de cruzamiento, que permite generar hijos a partir de padres seleccionados.

La Figura 3.2 muestra algunas formas de cruzamiento que pueden aplicarse, utilizando un sistema de representación de los cromosomas en cadenas de bits.

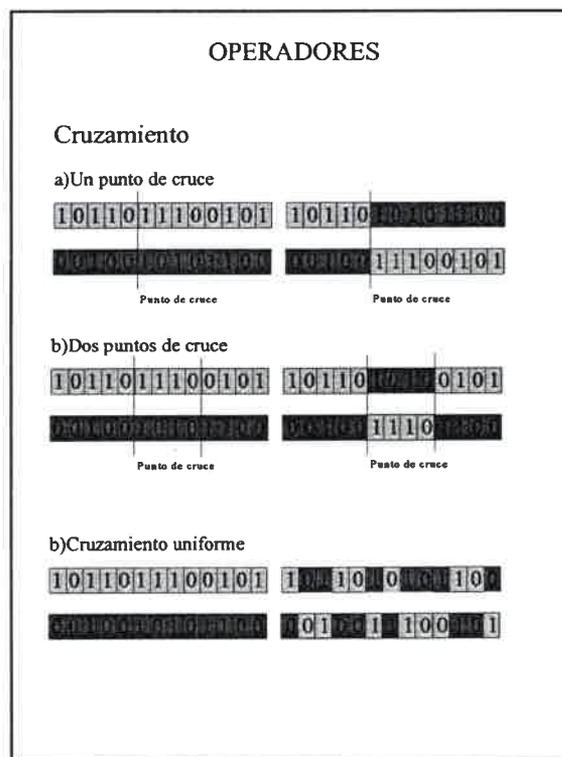


Figura 3.2. Operadores de cruzamiento

El cruzamiento con un *único punto de cruce* genera dos hijos a partir de los padres mediante el intercambio de las subcadenas posteriores al punto de cruce. Este se elige aleatoriamente entre los $l-1$ puntos posibles, siendo l la longitud del cromosoma.

El cruzamiento *por dos puntos de cruce* es similar al anterior; en este caso se intercambian las subcadenas de los padres ubicadas entre los dos puntos de cruce generados aleatoriamente.

El *cruzamiento uniforme* es una extensión del operador previamente citado, que consiste en intercambiar todos los bits homólogos entre los padres con una probabilidad del 50%. Esto también puede lograrse mediante una expresión lógica, generando una máscara en forma aleatoria del mismo largo que los cromosomas y procediendo de la siguiente manera: si el bit j de la máscara es 1, se copia el bit del padre en uno de los hijos y el de la madre en el otro hijo. En caso contrario la operación se invierte.

Existen otras formas de cruzamiento derivadas de las anteriores. El *cruzamiento segmentado* (Segmented crossover), propuesto por Eshelman (1989), opera en forma muy similar al cruzamiento multipunto salvo que el número de puntos de cruce no es fijo sino que puede variar alrededor de un valor esperado. Para ello se emplea una tasa de conmutación de segmentos que especifica la probabilidad que un segmento tenga fin en cualquier punto de la cadena. Si p_{co} es dicha probabilidad y l el largo del cromosoma, la cantidad de puntos de cruce esperada resulta el producto de ambas variables.

Eshelman (1989) cita además el *cruzamiento barajado* (shuffle crossover). Esta técnica, usada conjuntamente con cualquier cruzamiento multipunto reduce el sesgo posicional del operador estándar. Se procede barajando aleatoriamente las posiciones de los bits de los padres de la misma forma, para luego realizar un cruzamiento multipunto; finalmente se reordenan los bits del resultado a su posición inicial.

En el *cruzamiento semiuniforme* (half-uniform crossover), presentado por Spronck (1996), se realiza un cruzamiento uniforme entre los padres para obtener la descendencia y luego, se cruza cada hijo con uno de los padres. De esta manera se obtiene un mejor parecido con los progenitores.

En el trabajo de Esquivel (Esquivel, 1999) se mencionan dos tipos de cruzamiento múltiples: a) el *cruzamiento múltiple con un único par de padres* en el cual cada par de progenitores seleccionado origina múltiple descendencia de acuerdo al valor de aptitud asignando a la cupla de apareamiento. b) el *cruzamiento múltiple con múltiples padres* en el cual más de dos progenitores son utilizados para obtener descendencia.

Si bien se han comentado algunos de los operadores de cruzamiento más comunes, cada problema particular puede requerir la construcción de operadores de cruzamiento ad-hoc, dependiendo de la representación utilizada y de la estrategia de manejo de restricciones.

3.4.4.3 Operador de Mutación

El operador de mutación también dependerá, como ya se expresó, de la representación de los cromosomas. En el caso de representación por cadenas de bits, la mutación simplemente implica alterar bits de un cromosoma con cierta probabilidad. Esta operación implica decidir, en cada posición de la cadena y acorde con la probabilidad de mutación, si el bit se muta o no, tal como se representa en la Figura 3.3.

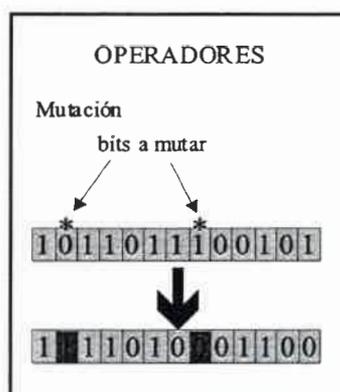


Figura 3.3. Operador de mutación

3.4.4.4 Elitismo

Se ha explicado que a partir de una generación dada se obtiene la siguiente por medio de los operadores descriptos. Los mejores individuos, si bien son los padres de los que forman la próxima generación, pueden quedar excluidos. El elitismo tiende a evitar dicha situación.

La incorporación de un número, n_{elit} , de mejores individuos o individuos de elite a la siguiente generación asegura que la próxima población tendrá siempre un individuo de igual o mejor ajuste que la anterior. El procedimiento consiste en copiar, antes de

comenzar a aplicar los operadores genéticos, los mejores n_{elit} individuos de una población a la siguiente; n_{elit} es un parámetro del AG.

3.4.5 Parámetros de los Algoritmos Evolutivos

Para que un AE pueda funcionar se deben definir un conjunto de valores llamados parámetros, entre los que se cuentan el tamaño de la población, el número máximo de iteraciones, la longitud de los individuos, la probabilidad de cruzamiento, la probabilidad de mutación y otros que son característicos de cada método particular, como por ejemplo: coeficientes de la función de penalización, tamaño de la vecindad en poblaciones estructuradas, etc.

Si bien no existen criterios definitivos para la selección de los valores a asignar al conjunto de parámetros, pueden encontrarse en la literatura ciertas recomendaciones de carácter general y otras específicas asociadas con la probabilidad de cruzamiento (p_c) y la probabilidad de mutación (p_m).

La probabilidad de cruzamiento se define como la relación entre el número esperado de hijos producidos en cada generación y el tamaño de la población; por lo tanto controla el número promedio de cromosomas que serán sometidos al operador de cruzamiento. Se han reportado valores de $p_c = 0.6$ y valores de $p_c \in [0.75 - 0.95]$ (Bäck, 1997).

La probabilidad de mutación está relacionada con el número esperado de bits a mutar en cada generación y en contraposición al cruzamiento, la mutación es introducida con una probabilidad de ocurrencia no superior a 0.05; aunque también se han reportado valores de $p_m = 1/l$ donde l corresponde a la longitud del cromosoma binario que representa la solución (Bäck, 1997).

El tamaño de la población (N) constituye un parámetro de gran importancia en el diseño de un AE. Puede decirse que en general valores pequeños de N conducen a una convergencia temprana del algoritmo, en tanto que valores muy grandes exigen un esfuerzo computacional alto sin lograr con esto un mejor desempeño del algoritmo.

El número máximo de generaciones, T , es un criterio de detención posible del algoritmo y los valores utilizados en la literatura varían en un rango muy amplio. Otras condiciones de terminación utilizadas son por ejemplo: 1) medir el progreso realizado por el algoritmo en un número predefinido de generaciones y detener la búsqueda cuando tal progreso es menor que algún valor dado; 2) correr el algoritmo hasta que la población se haya estabilizado, es decir, cuando todos o la mayoría de los individuos tengan la misma aptitud (Michalewicz, 1996); etc.

3.4.6 Manejo de las restricciones

Un problema muy importante al aplicar AG en optimización restringida es el manejo de las restricciones, ya que a menudo los operadores genéticos utilizados durante el proceso evolutivo pueden generar soluciones no factibles. Entre las técnicas empleadas merecen destacarse las mencionadas a continuación (Gen, 1996).

3.4.6.1 Estrategias de rechazo

Dentro de esta categoría la heurística de *pena de muerte* es una opción común o popular en varias técnicas evolutivas. El método consiste en eliminar las soluciones no factibles de la población. Produce buenos resultados si el espacio de búsqueda es convexo y constituye una parte razonable del espacio de búsqueda total.

3.4.6.2 Estrategias de Reparación

Consiste en tomar una solución no factible y generar una factible a través de algún procedimiento de modificación o enmienda. Esta técnica es muy dependiente del problema particular y se han reportado desde casos de muy exitosa aplicación (Gen, 1996), hasta ejemplos en los cuales reparar un individuo no factible se transforma en un problema tan complejo como el original (Michalewicz, 1996).

3.4.6.3 Estrategias de penalización

En este enfoque el problema *restringido* se transforma en un problema no restringido penalizando las soluciones no factibles. Esto se realiza adicionando un

término a la función de adaptabilidad, que depende del grado de violación de las restricciones (Goldberg, 1989):

$$F_i = f(cr_i) + R Q(cr_i) \quad (3.6)$$

donde f representa la función objetivo, Q tiene en cuenta las violaciones al conjunto de restricciones y R es un coeficiente de penalización.

Otra alternativa es por ejemplo la propuesta por Deb (Deb, 2000), donde se utiliza la siguiente expresión para la función de fitness:

$$F_i = \begin{cases} f(cr_i) & \text{si } cr_i \text{ es factible} \\ f_{\max} + Q(cr_i) & \text{si } cr_i \text{ es no factible} \end{cases} \quad (3.7)$$

donde f_{\max} es el valor máximo de la función objetivo sobre todos los individuos factibles de la población.

3.4.6.4 Modificación de los operadores genéticos:

En este enfoque los operadores de mutación y entrecruzamiento se diseñan en forma ad-hoc para un problema particular con el fin de preservar la factibilidad de cada solución.

3.5 Conclusiones

En este capítulo se presentó el Diseño de Redes de Sensores como un problema de optimización combinatorial. La complejidad computacional asociada al mismo depende del diseño particular que se plantee.

Algunos casos pueden resolverse con algoritmos de tiempo polinomial, otros (de tamaño relativamente pequeño) son susceptibles de encontrar el óptimo a través de algoritmos exponenciales. Cuando el tamaño de la instancia es mayor (y a medida que el problema se acerca al caso real, con restricciones) el costo computacional torna impracticables los métodos anteriores y los AE emergen como una alternativa válida.

En este sentido se ha explicado el funcionamiento de un AE simple y los ejemplos dados corresponden a la representación de cromosomas como cadenas de bits, para la cual los operadores de cruzamiento por puntos de cruce único o múltiple dan como resultado otra cadena de bits igualmente válida. Para resolver problemas sujetos a restricciones pueden utilizarse técnicas de reparación, de penalización o modificación de operadores genéticos.

La aplicación de un AE a un problema real requerirá en la mayoría de los casos la modificación del AG puro, ya sea a nivel de la representación utilizada, de la generación de la población inicial o en la adaptación de nuevos operadores genéticos por analogía con los definidos para representación binaria. Esto significa que el conocimiento experto que se posea del problema, jugará un rol muy importante en el diseño del algoritmo.

Como último punto cabe destacar que dado un AE, es posible mejorar su desempeño en algunos casos al combinarlo con otras técnicas de optimización, para dar lugar a un algoritmo híbrido. Una de las formas más comunes de realizar la hibridización es incorporando una búsqueda local en el lazo de selección y reproducción del AG. De esta manera, mientras que el AG realiza una exploración global del espacio de búsqueda, se utiliza otra heurística para explotar las vecindades de las buenas soluciones.

Nomenclatura del Capítulo III

- A conjunto de índices (subconjunto de los naturales)
- cr_i individuo de la población P
- C función de complejidad computacional de un algoritmo
- c_j transformaciones tipo cruzamiento
- C_o tamaño de un torneo
- E tamaño de la entrada de un problema
- f función objetivo
- F_i valor de fitness del individuo i
- FT suma de los fitness individuales
- G conjunto de puntos factibles
- g^* óptimo global
- I conjunto de instancias de un problema de optimización
- k índice del rango
- l longitud del cromosoma
- m_i transformaciones tipo mutación
- N número de individuos en la población P
- P población de individuos
- P familia de partes de A
- p función tipo polinomio
- p_c probabilidad de cruzamiento
- p_m probabilidad de mutación
- p_s probabilidad de selección
- p_{co} probabilidad de conmutación

- Q función de penalización
- q vector de variables binarias
- Rc coeficiente de penalización
- R^n conjunto de vectores reales n -dimensionales
- S estructura de datos
- T número máximo de generaciones del algoritmo
- u vector de variables no medidas
- x vector de mediciones

Letras Griegas

- n_{elit} tamaño del conjunto de élite
- η_{max} número esperado de veces que el mejor individuo es seleccionado

CAPITULO IV

DISEÑO DE REDES DE SENSORES MÍNIMAS

4.1 Introducción

En este capítulo se presentan distintas estrategias de solución para el diseño de redes de mínimo número de sensores. Para un cierto subconjunto de criterios de optimización, el algoritmo goloso (*greedy*) permite resolver el problema. En el caso de funciones objetivo más complejas, es necesario implementar técnicas determinísticas particulares o estrategias evolutivas. En este contexto, se presenta un nuevo procedimiento basado en la aplicación de AE y conceptos del álgebra lineal. La satisfacción de la restricción de observabilidad, implícita en el problema a resolver, se garantiza a través de la modificación de los operadores de cruzamiento y mutación estándares.

En contraste con los algoritmos determinísticos, los cuales encuentran la solución de diseño para un criterio específico, la estrategia propuesta permite resolver el problema con diferentes funciones objetivo utilizando la misma implementación. Más aún, modificando solamente el operador de selección, el código puede ser extendido para manejar problemas multiobjetivo.

4.2 Formulación General del Problema

Tal como fuera presentado en el Capítulo 2, los balances de masa de un proceso que opera en condiciones de estado estacionario, pueden representarse por el siguiente conjunto de ecuaciones algebraicas lineales:

$$\mathbf{D} \mathbf{z} = \mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{u} = 0 \quad (4.1)$$

donde \mathbf{D} es la matriz de incidencia del proceso de dimensión $(m \times n)$, \mathbf{z} es el vector de flujos de dimensión n , \mathbf{x} representa el vector de variables medidas, \mathbf{u} corresponde al vector de variables no medidas y las matrices \mathbf{A} y \mathbf{B} son submatrices compatibles de \mathbf{D} .

El diseño óptimo de una red de sensores no redundantes, que asegure la observabilidad de todas las variables no medidas, implica la selección de un conjunto de $g = (n-m)$ mediciones de flujo que permitan estimar todos los flujos no medidos, al mismo tiempo que se optimiza un dado objetivo del Sistema de Instrumentación.

La observabilidad de todas las variables no medidas, para un cierto conjunto de mediciones, está garantizada si el rango de \mathbf{B} es m (Romagnoli y Sánchez, 1999). Por lo tanto, el problema general de diseño de redes de sensores (Ecuación 1.1) se reduce a la siguiente formulación:

$$\begin{aligned} & \underset{\mathbf{q}}{\text{Min/Max}} && \mathbf{f}(\mathbf{q}) \\ & \text{s.t.} && \text{rango}(\mathbf{B}(\mathbf{q})) = r_{\mathbf{B}} = m \end{aligned} \quad (4.2)$$

para el diseño de redes mínimas, donde \mathbf{f} representa un criterio de optimización simple o múltiple.

De acuerdo al criterio de optimización seleccionado, pueden considerarse diferentes estrategias de solución al problema de optimización combinatorial. En el caso de diseños óptimos que cumplan con ciertas condiciones matemáticas especiales, se puede utilizar un algoritmo goloso. Para la resolución de problemas más complejos, se han propuesto, durante la ejecución de esta tesis, nuevas técnicas evolutivas basadas en AG y conceptos del álgebra lineal.

4.3 El Algoritmo Goloso

En esta sección se presenta la potencialidad del algoritmo goloso para la resolución de la subclase del problema de optimización (4.2), correspondiente a las funciones objetivo costo total y confiabilidad del sistema de instrumentación.

Definición: Un sistema de subconjuntos, $S = (E, \theta)$, es un conjunto finito E junto con una colección θ , de subconjuntos de E cerrados bajo inclusión (ésto es, si $N \in \theta$ y $N' \subseteq N$, entonces $N' \in \theta$). Los elementos de θ son llamados independientes.

Además se asocia el siguiente *problema de optimización combinatorial* al sistema de subconjuntos $S = (E, \theta)$: Dado un peso fijo $w(e) \geq 0$ para cada $e \in E$, encontrar un subconjunto independiente θ que tenga el peso total posible más grande.

Si S es un sistema de subconjuntos que verifica que para cualquier subconjunto $T \in E$, cada subconjunto independiente maximal en T tiene la misma cardinalidad, entonces se dice que S es un matroide. Esto es equivalente a afirmar que el algoritmo goloso resuelve en tiempo polinomial cualquier instancia del problema combinatorio asociado con S (Papadimitriou, 1982).

En el caso del problema planteado en la ecuación (4.2), si se considera que:

- a) E es el conjunto de columnas de la matriz D , éste es el conjunto de columnas de una matriz de tamaño $(m \times |E|)$,
- b) θ es la colección de conjuntos de columnas de D linealmente independientes, o sea la colección de matrices B de rango completo,
- c) w_i es el costo de cada instrumento c_i , que puede ser localizado para medir el i -ésimo flujo de masa,

entonces: el sistema de subconjuntos $S = (E, \theta)$ es un matroide, ya que todos los subconjuntos linealmente independientes maximales de un conjunto de vectores E' comparten la misma cardinalidad. En álgebra lineal esta cardinalidad es llamada precisamente, el rango de la submatriz B' definida por E' . Por consiguiente, el siguiente problema de optimización discreta

$$\begin{aligned} \text{Min}_{\mathbf{q}} \quad CT &= \sum_{i=1}^n c_i q_i \\ \text{s.t.} & \\ \text{rango}(\mathbf{B}(\mathbf{q})) &= r_B = m \end{aligned} \tag{4.3}$$

puede ser resuelto eficientemente utilizando el Algoritmo Goloso (Carnero y co., 2001b).

El problema (4.3) es un caso particular del problema general de diseño de redes mínimas (4.2), en el cuál se considera el costo de capital total CT como la función objetivo.

El procedimiento de solución del Algoritmo Goloso se presenta a continuación:

```

/*****
/* Algoritmo Goloso*/
*****/
comenzar
I: =  $\emptyset$ 
mientras E  $\neq \emptyset$  hacer
  comenzar
  sea e el elemento de E que tiene el mayor/menor peso
  eliminar e de E
  si  $I+e \in \Theta$  entonces I: = I + e
  fin
fin

```

A continuación se ilustra el comportamiento del Algoritmo Goloso, para determinar el mínimo costo de instrumentación de la red de amoníaco simplificada, mostrada en la Figura 4.1.

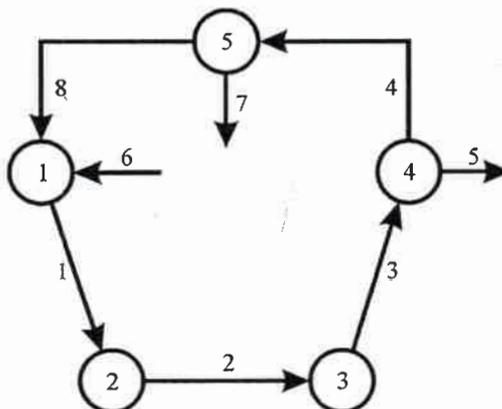


Figura 4.1. Diagrama de flujo para una planta de amoníaco

Esta involucra 5 unidades y 8 corrientes; su matriz de incidencia es la siguiente:

de falla acumulada. Si se define E como el conjunto de columnas de la matriz D , θ como la colección de conjuntos constituídos por las columnas de D linealmente independientes, y w_i como la confiabilidad de cada medición, ésto es, $[1 - pfa_i(t)]$, demostramos que el problema de diseño antes mencionado puede también ser resuelto utilizando el Algoritmo Goloso, tal como se demostró en el trabajo de Carnero y co. (2001b).

Considérese nuevamente el proceso ilustrado en la Figura 4.1. El Algoritmo Goloso se aplica para maximizar la confiabilidad del sistema en el caso de una estructura de sensores no redundantes. El vector probabilidad de falla es $\mathbf{pfa}^T = [0.141 \ 0.104 \ 0.07 \ 0.165 \ 0.052 \ 0.17 \ 0.128 \ 0.154]$. En este caso el conjunto óptimo de mediciones corresponde a las corrientes [3 5 7] y la confiabilidad máxima del sistema es $R_s(t) = 0.769$.

4.3.1 Limitaciones del Algoritmo Goloso

Este procedimiento permite obtener el óptimo global en los problemas de diseño mencionados anteriormente, ya que las funciones objetivo son tales que permiten asociar a cada miembro de E , un peso constante, para el mismo conjunto de restricciones. Sin embargo existen criterios simples o múltiples que no verifican tal condición.

Para el caso de objetivos simples, si se considera a modo de ejemplo la precisión global definida por Kretsovalis y Mah (1987), resulta el siguiente problema de optimización:

$$\begin{aligned} \text{Min}_{\mathbf{q}} \quad GI &= \sum_{i=1}^n [\sigma_i^2 q_i + \hat{\sigma}_i^2(\mathbf{q})(1 - q_i)] \\ \text{s.t.} \quad & \Gamma_B = m \end{aligned} \tag{4.5}$$

donde $\hat{\sigma}_i^2$ es la varianza de i -ésima variable estimada. Si i es una variable medida ($q_i=1$) entonces $\hat{\sigma}_i^2 = \sigma_i^2$, donde σ_i^2 es la desviación estándar del i -ésimo error de

medición, pero si i corresponde a una variable no medida ($q_i=0$), $\hat{\sigma}_i^2$ depende de la desviación estándar, σ_i^2 , de las variables medidas usadas para calcularla. En este caso el Algoritmo Goloso no puede ser aplicado ya que $\hat{\sigma}_i^2$ no es un peso constante.

Si la función objetivo es la confiabilidad mínima en la estimación de todas las variables (Ali y Narasimhan, 1993), y se pretende maximizar su valor, el problema de optimización resultante se formula como sigue:

$$\begin{aligned} & \underset{\mathbf{q}}{\text{Max}} \quad \underset{\mathbf{q}}{\text{Min}} \quad R_v(\mathbf{q}) \\ & \text{s.t.} \quad r_B = m \end{aligned} \tag{4.6}$$

siendo R_v la confiabilidad de la estimación de cualquier variable del proceso. Dado que la función objetivo no puede formularse en términos de pesos constantes, el Algoritmo Goloso no es adecuado para resolver el problema anterior.

En vista de las limitaciones del Algoritmo Goloso para abordar ciertos problemas de diseño, emergen dos alternativas para su resolución: 1) aplicar estrategias determinísticas para cada criterio/s específico/s 2) aplicar un procedimiento estocástico que permita optimizar cualquier criterio simple y pueda ser extendido sin dificultad, a casos multiobjetivo. La segunda alternativa resulta más flexible y es el enfoque adoptado en esta tesis.

A continuación se presenta una nueva técnica evolutiva, que aplica los bien conocidos conceptos del álgebra lineal, para resolver el problema de diseño de redes de sensores mínimas. En primer lugar se describe la metodología propuesta para resolver problemas que satisfacen criterios de optimización simples del Sistema de Instrumentación y luego se discute su extensión para la búsqueda de soluciones que satisfacen múltiples criterios de optimización.

4.4 Nuevo Enfoque Evolutivo para Diseño Optimo con Criterio Simple

Dado que, como se mencionó en el Capítulo 3, el AG simple no está diseñado para resolver problemas con restricciones, es necesario aplicar alguna técnica para su manejo. La modificación de los operadores genéticos con tal fin resulta la característica distintiva de la estrategia evolutiva propuesta (Carnero y co., 1999). Esta comprende la ejecución de las siguientes etapas:

a) Representación de la Solución

El cromosoma se representa por una cadena binaria, \mathbf{q} , de largo fijo, n , tal como se utiliza en un AG simple.

b) Determinación de la Población Inicial

En contraste con el AG clásico se comienza con una población inicial factible, que se obtiene de la siguiente forma:

i) Se selecciona un conjunto cualquiera de variables no medidas, de modo tal que satisfaga la condición de rango completo sobre \mathbf{B} . Por lo tanto, se genera una solución factible \mathbf{q}_0 del problema.

ii) La matriz \mathbf{D} se divide en las submatrices \mathbf{A} ($m \times g$) y \mathbf{B} ($m \times m$), siendo la primera la correspondiente a las variables medidas.

iii) Dado que la matriz cuadrada \mathbf{B} tiene rango completo, existe por lo tanto la matriz inversa \mathbf{B}^{-1} , en consecuencia el vector de variables no medidas \mathbf{u} puede formularse como

$$\mathbf{u} = -\mathbf{B}^{-1} \mathbf{A} \mathbf{x} = \mathbf{R} \mathbf{x} \quad (4.7)$$

El i -ésimo elemento del vector \mathbf{u} se evalúa mediante la siguiente expresión:

$$u_i = \sum_{j=1}^{j=g} r_{ij} x_j \quad \forall i = 1 \dots m; \quad \forall j = 1 \dots g. \quad (4.8)$$

iv) La matriz **R** contiene la información necesaria para determinar el par de variables medidas y no medidas pertenecientes a \mathbf{q}_0 que pueden ser intercambiadas mientras se preserva la observabilidad del sistema. Los miembros de una población factible se generan aplicando la siguiente definición: “Un par de variables (u_i, x_j) pueden ser intercambiadas si el coeficiente $r_{ij} \neq 0$ ”.

Como ejemplo, considérese una matriz **D** de tamaño (3 x 6)

$$\mathbf{D} = \begin{bmatrix} 1 & -1 & 0 & -1 & 0 & 0 \\ 0 & 1 & -1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & -1 & 0 \end{bmatrix}$$

Si $\mathbf{q}_0 = [1 \ 1 \ 1 \ 0 \ 0 \ 0]$, entonces **R** es la siguiente matriz de (3x3)

$$\mathbf{R} = \begin{bmatrix} 1 & -1 & 0 \\ 1 & -1 & 0 \\ 0 & -1 & 1 \end{bmatrix}$$

a partir de la cual el vector **u** se estima como sigue

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \end{bmatrix} = \begin{bmatrix} x_1 - x_2 + 0x_3 \\ x_1 - x_2 + 0x_3 \\ 0x_1 - x_2 + x_3 \end{bmatrix}$$

donde u_1 corresponde al flujo z_4 , u_2 al flujo z_5 y u_3 al z_6 . Puede observarse que los intercambios factibles son (x_1, u_1) ; (x_2, u_1) , (x_1, u_2) , (x_2, u_2) , (x_2, u_3) y (x_3, u_3) . Cada intercambio origina una nueva matriz **B** de dimensión (3x3) de rango completo.

c) **Selección**

Se utiliza la selección proporcional, tal como se la describió en 3.4.4.

d) **Cruzamiento**

Dadas dos soluciones factibles \mathbf{q}_1 y \mathbf{q}_2 , la operación de cruzamiento se efectúa mediante el siguiente procedimiento:

Se computan dos vectores, \mathbf{px}_i y \mathbf{pu}_i , que almacenan la posición ordinal de unos y ceros de cada cromosoma \mathbf{q}_i .

Se definen los conjuntos $K = \{k \mid \mathbf{px}_1(k) \neq 0\}$, $L = \{l \mid \mathbf{px}_2(l) \neq 0\}$ y

$$H = K \cap L.$$

Si existe por lo menos un elemento k en K y un elemento l en L , tal que ambos no pertenezcan a H , entonces se fijan los siguientes valores para los subíndices i, j, s y b : $i = \mathbf{pu}_1(l), j = \mathbf{px}_1(k), s = \mathbf{pu}_2(k), b = \mathbf{px}_2(l)$.

Si $r_{1,i,j} \neq 0$ (para \mathbf{R}_1 asociada al cromosoma \mathbf{q}_1) y $r_{2,s,b} \neq 0$ (para \mathbf{R}_2 asociada al cromosoma \mathbf{q}_2) entonces, el primer descendiente adopta los elementos de \mathbf{q}_2 en las posiciones (k,l) ; del mismo modo el segundo descendiente adopta los elementos de \mathbf{q}_1 en las mismas posiciones.

Supóngase que se obtienen, para el ejemplo anterior, dos padres factibles, representados por las cadenas $\mathbf{q}_1 = (111000)$ y $\mathbf{q}_2 = (100011)$. Las correspondientes matrices \mathbf{R}_i son

$$\mathbf{R}_1 = \begin{bmatrix} 1 & -1 & 0 \\ 1 & -1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \quad \mathbf{R}_2 = \begin{bmatrix} 1 & -1 & 0 \\ 1 & -1 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Las posiciones ordinales de unos y ceros para cada cromosoma están contenidas en los siguientes vectores:

$$\mathbf{px}_1=[1\ 2\ 3\ 0\ 0\ 0], \quad \mathbf{pu}_1=[0\ 0\ 0\ 1\ 2\ 3],$$

$$\mathbf{px}_2=[1\ 0\ 0\ 0\ 2\ 3], \quad \mathbf{pu}_2=[0\ 1\ 2\ 3\ 0\ 0],$$

a partir de los cuales se obtienen los conjuntos K , L y H : $K = \{1,2,3\}$, $L = \{1,5,6\}$, $H = \{1\}$. El conjunto intersección H contiene sólo una variable en la posición 1, por lo tanto las variables en posición 2 y 3 de \mathbf{q}_1 y en posición 5 y 6 de \mathbf{q}_2 pueden ser consideradas para intercambio. Si se selecciona el par (2,5), entonces $i=\mathbf{pu}_1(5)=2$, $j=\mathbf{px}_1(2)=2$, $s=\mathbf{pu}_2(2)=1$, $b=\mathbf{px}_2(5)=2$.

Los coeficientes r_{22} de \mathbf{R}_1 y r_{12} de \mathbf{R}_2 son inspeccionados. Como ellos no son cero, resultan los siguientes hijos: $\mathbf{o}_1=(1\ 0\ 1\ 0\ 1\ 0)$; $\mathbf{o}_2=(1\ 1\ 0\ 0\ 0\ 1)$.

e) Mutación

La operación de mutación se aplica a un miembro de la población factible si su probabilidad de mutación excede a cierto valor prefijado. En este caso, una medición seleccionada al azar es reemplazada por una variable no medida de menor costo mientras se preserva la observabilidad del sistema.

Por ejemplo si, continuando con el caso anterior, se considera el cromosoma $\mathbf{q}_0=(1\ 1\ 1\ 0\ 0\ 0)$ y la variable medida x_1 es seleccionada para mutación, ésta puede ser intercambiada tanto con u_1 como con u_2 . Suponiendo que u_1 es la variable de menor costo, el cromosoma mutado resulta $\mathbf{q}_0^*=(0\ 1\ 1\ 1\ 0\ 0)$.

4.4.1 Ejemplo de Aplicación

A continuación se muestra un ejemplo de aplicación de la estrategia evolutiva propuesta, correspondiente al diseño de redes de sensores mínimas para la planta de amoníaco simplificada de la Figura 4.1.

En la Tabla 4.1 se listan los datos del ejemplo; para cada variable se indica el valor verdadero del flujo obtenido por simulación, el costo del caudalímetro disponible y el desvío estándar del error de la medición, expresado como porcentaje del valor verdadero.

Corriente	Flujos(kg/h)	Costo(\$)	σ
1	1000	1000	3%
2	1000	1500	2%
3	1000	2500	1.5%
4	600	1500	2%
5	400	1500	2%
6	550	2500	1.5%
7	150	1000	3%
8	450	1500	2%

Tabla 4.1. Datos para la planta de amoníaco

En la Tabla 4.2 se presentan los parámetros del algoritmo utilizado y en la Tabla 4.3 se muestran los resultados del diseño óptimo cuando se consideran diferentes funciones objetivo.

Parámetro	Valor
Tamaño de la Población	11
Probabilidad de cruzamiento	0.7
Probabilidad de Mutación	0.05
Número de generaciones	20

Tabla 4.2. Parámetros del AE

Criterio	Valor Función Objetivo	Flujos Medidos
GI	806.06	6 7 8
R_v	0.7719	3 5 6
CT	3500	1 7 8
	3500	1 5 7
R_s	0.769	3 5 7

Tabla 4.3. Resultados de la optimización

4.5 Nuevo Enfoque Evolutivo para Diseño Optimo con Criterios Múltiples

4.5.1 Optimización Multiobjetivo: su Resolución Matemática

Se han propuesto diferentes medidas de desempeño para cuantificar la calidad de la información que brinda un sistema de sensores. Entre ellas cabe destacar la precisión, la confiabilidad o disponibilidad y la robustez de las estimaciones (Bagajewicz, 2002). Además es necesario considerar el costo en el ciclo de vida del Sistema de Instrumentación (Sánchez y Bagajewicz, 2000). La consideración simultánea de estos objetivos diferentes convierte al problema de diseño óptimo de redes de sensores en uno de optimización multiobjetivo. En esta situación, el vector $\mathbf{f}(\mathbf{q})$ utilizado en la definición general del problema, Ecuación 4.2, comprende funciones $f_a(\mathbf{q})$ ($a=1,2,\dots, nof$) que representan criterios de optimización individuales.

Los principios de la optimización con criterio simple y múltiple son notablemente diferentes. En la primera, la meta es encontrar la “mejor” solución de diseño, es decir el óptimo global para una función objetivo simple. En cambio, en la optimización multiobjetivo es posible que no exista una solución que sea la mejor con respecto a todos los objetivos. En general existirán un conjunto de soluciones que son superiores a las restantes cuando se consideran simultáneamente todos los objetivos, pero que son inferiores a otras soluciones en el espacio de búsqueda de uno o más criterios de optimización.

Los problemas de optimización multiobjetivo con funciones objetivos en conflicto dan lugar a un *conjunto de soluciones óptimas*, en lugar de una única solución, a las cuales se las denomina soluciones Pareto Óptimas, cuya definición se incluye a continuación.

Definición: Se dice que una solución q domina a otra solución p si se verifican simultáneamente las siguientes condiciones:

- a) La solución q no es peor (el operador \prec denota peor y el operador \succ denota mejor) que p en todos los objetivos, ésto es $f_a(q) \not\prec f_a(p) \quad \forall a=1,2,\dots,nof$,
- b) La solución q es estrictamente mejor que p por lo menos en un objetivo, ésto es $f_a(q) \succ f_a(p)$ para algún $a \in \{1,2,\dots,nof\}$.

Todas las soluciones no dominadas forman el conjunto P de soluciones Pareto Óptimas; los correspondientes vectores objetivo forman la *superficie o el frente Pareto óptimo*.

En la resolución de problemas de optimización multiobjetivo pueden identificarse dos clases de dificultades conceptualmente diferentes: una relacionada con la búsqueda de soluciones y otra con la toma de decisiones. El primer aspecto se refiere al proceso de optimización en si mismo, en el que el conjunto factible se muestrea para obtener las soluciones Pareto. El segundo aspecto es la selección de una solución de compromiso adecuada a partir del conjunto Pareto.

Dependiendo de cómo sean combinados estos aspectos, los métodos de optimización multiobjetivo se clasifican como sigue:

- a) Toma de decisiones antes de la búsqueda: Los objetivos del problema son combinados en una sola función objetivo, parametrizada, que implícitamente incluye información adicional sobre la preferencia o peso dado a cada objetivo.

- b) Búsqueda anterior a la toma de decisiones: La optimización se lleva a cabo sin ninguna información de preferencia dada. El resultado es un conjunto de soluciones, que son idealmente Pareto-óptimas, a partir del cual se realiza la selección final.

Los métodos clásicos utilizan el primer criterio mencionado en el punto anterior, donde los parámetros son sistemáticamente variados por el optimizador. Para obtener un conjunto de soluciones, se ejecutan varias corridas con diferentes valores de parámetros. Entre estas técnicas cabe destacar las siguientes:

- a) Método de los pesos: el problema original (4.2) se convierte a uno de simple objetivo formado por una combinación lineal de los *nof* objetivos

$$\begin{aligned} \underset{\mathbf{q}}{\text{Min/Max}} \quad & w_1 f_1 + w_2 f_2 + \dots + w_{\text{nof}} f_{\text{nof}} \\ \text{s.t.} \quad & \text{rango}(\mathbf{B}(\mathbf{q})) = r_B = m \end{aligned} \tag{4.9}$$

Los pesos w_i son generalmente normalizados de modo tal que $\sum_{i=1}^{\text{nof}} w_i = 1$.

Suponiendo que se cuenta con un algoritmo de optimización exacto, resolviendo el problema anterior para diferentes combinaciones de pesos, puede encontrarse, potencialmente, un conjunto de soluciones Pareto. La principal desventaja de esta técnica es su incapacidad de generar todas las soluciones Pareto cuando el frente o la superficie Pareto es no convexa. En otras palabras, este método exhibe un sesgo hacia las porciones convexas del frente Pareto.

- b) Método de las restricciones: para evitar el sesgo hacia las regiones convexas del frente Pareto óptimo, esta técnica propone transformar (*nof*-1) objetivos en restricciones. La función objetivo restante, que puede ser elegida en forma arbitraria, es la función objetivo del problema de simple objetivo resultante.

Los límites inferiores son los parámetros que se varían durante la optimización a fin de encontrar las soluciones múltiples. Sin embargo, si éstos no son elegidos apropiadamente, puede darse el caso de tener una región factible vacía. Esto implica tener a priori, un conocimiento profundo del problema, el cual puede no estar disponible.

Los AE se presentan nuevamente como una alternativa a los métodos clásicos a través de los cuales:

- Pueden manejarse espacios de búsqueda grandes
- Pueden generarse múltiples soluciones Pareto en una única corrida
- Puede evitarse, mediante una implementación adecuada, la sensibilidad hacia regiones Pareto convexas.

Existen en la actualidad varios métodos basados en un enfoque estocástico para resolver problemas de optimización multiobjetivo. Las dos principales cuestiones a tener en cuenta cuando se aplica un AE a la resolución de este tipo de problemas son:

- a) Como llevar a cabo la asignación de fitness y por consiguiente la selección, con el propósito de dirigir la búsqueda hacia el conjunto Pareto-óptimo.
- b) Mantener cierta diversidad en la población en el frente Pareto óptimo, con el fin de obtener un conjunto de soluciones no dominadas con una distribución uniforme y extendida.

La forma de resolver las dificultades previamente mencionadas ha dado origen a diferentes métodos. Schaffer (1984, 1985) propone un AE denominado “*Vector Evaluating Genetic Algorithm*” en el cual la selección se realiza para los *nof* objetivos separadamente, llenando porciones de igual tamaño del conjunto de apareamiento. El cruzamiento y mutación son los estándares.

Este procedimiento presenta un sesgo potencial en detrimento de los individuos de desempeño medio, es decir aquellos que son buenas soluciones, pero no excelentes con respecto a algún criterio específico.

Srinivas (Srinivas y Deb, 1994) propone la metodología llamada NSGA “*Nondominated Sorting Genetic Algorithm*”. En este procedimiento, basado en una idea de Goldberg (1989), se utiliza también el concepto de Pareto dominancia para la asignación de fitness. Primero se le asigna rango uno a todos los individuos no dominados y se los elimina temporalmente de la población. Este conjunto constituye, lo que se denomina el primer frente. A los siguientes individuos no dominados se les asigna rango dos, y así sucesivamente, de modo tal que al final de este procedimiento, la población se ha dividido en b frentes.

Finalmente, se determina un mismo valor de fitness ficticio, F'_k ($k = 1, \dots, b$), para todos los individuos pertenecientes al k -ésimo frente, con el fin de otorgarle un mismo potencial de reproducción.

Para mantener la diversidad de la población se utiliza una técnica de distribución (*sharing*) del fitness ficticio. Esta técnica intenta promover la formación y mantenimiento de subpoblaciones estables, llamadas *nichos*. Se basa en la idea que los individuos pertenecientes a un nicho particular tienen que compartir los recursos disponibles. Cuantos más individuos estén localizados en la vecindad de un individuo particular, su valor de fitness se degrada más en relación con el fitness ficticio del frente al que pertenece.

El término vecindad se define en relación a alguna medida de distancia o norma, especificada por el denominado *radio de nicho*, r_n . En cuanto a la degradación del fitness, para cada individuo \mathbf{q} perteneciente a un frente dado $\overline{\mathbf{P}}_k$, el valor de fitness ficticio del frente se divide por una cantidad proporcional al número de individuos que lo rodean, tal como indica la siguiente expresión:

$$F(\mathbf{q}) = \frac{F'_k}{\sum_{\mathbf{p} \in P_k} Sh(d(\mathbf{q}, \mathbf{p}))} \quad (4.10)$$

donde

$$Sh(d(\mathbf{q}, \mathbf{p})) = \begin{cases} 1 - \left(\frac{d(\mathbf{p}, \mathbf{q})}{r_n} \right)^2 & \text{si } d(\mathbf{q}, \mathbf{p}) \leq r_n \\ 0 & \text{en caso contrario} \end{cases} \quad (4.11)$$

siendo $d(\mathbf{q}, \mathbf{p})$ la distancia entre la solución \mathbf{p} y la solución \mathbf{q} .

Este nuevo valor de *fitness* degradado se emplea para llevar a cabo el proceso de selección. Una vez que la población entera ha sido clasificada se utiliza un esquema de selección proporcional estocástica por restos (*Stochastic Remainder Proportionate Selection, SRPS*). Este asegura que los individuos en el primer frente obtienen más copias para reproducción que el resto de la población. Se pueden encontrar versiones actualizadas de este algoritmo en la publicación de Deb (2001).

Dependiendo de cuál es el espacio utilizado para definir la distancia se habla de *sharing* genotípico, fenotípico o *sharing* en el espacio objetivo. En los casos donde el problema está definido en el espacio genotípico, ésto es la solución y su codificación coinciden, la distancia $d(\mathbf{q}, \mathbf{p})$ se calcula utilizando el número de bits diferentes entre la solución \mathbf{q} y la solución \mathbf{p} , a la que se denomina distancia de Hamming.

Fonseca y Fleming (1993) implementaron una versión diferente de la idea de Goldberg (1989). En una primera etapa la población completa es revisada y a los individuos no dominados se les asigna rango 1(uno). El resto de los individuos son clasificados de la siguiente forma : dada una solución particular se encuentra primero el número de soluciones que estrictamente la dominan, luego el rango asignado a ésta es 1(uno) más este número. Al final de este procedimiento pueden existir varias soluciones con el mismo rango.

En una segunda etapa la población es ordenada de acuerdo a su rango y se le

asigna a cada individuo un valor de *fitness* bruto utilizando el ranking lineal propuesto por Baker (Baker, 1985).

Por último se asigna el valor de *fitness* promediando y aplicando la función de sharing sobre los valores de *fitness* crudo que tienen idéntico rango (*fitness sharing* sobre la función objetivo). El conjunto de apareamiento se llena utilizando un muestreo estocástico universal.

4.5.2 Descripción de la Estrategia Propuesta

En este trabajo se desarrolla una metodología basada en el enfoque original propuesto por Srinivas y Deb, donde se incorpora elitismo. Este consiste en incluir los mejores individuos de la generación anterior en la generación actual con el objetivo de evitar la pérdida de “buenas” soluciones debido a los efectos de muestreo. A continuación se describen las etapas de la estrategia propuesta (Carnero y co., 2001a y b):

a) **Inicialización:** generación de la población inicial \mathbf{P}_0 , de acuerdo a la técnica propuesta en la Sección 4.4 y creación de un vector de elite externo $\mathbf{P}_{\text{elite}} = \mathbf{0}$

b) **Construcción de los diferentes frentes y asignación de fitness:**

i) Asignar $\mathbf{P}_{\text{auxiliar}} = \mathbf{P}(t)$; e inicializar el valor de fitness ficticio en $F^* = 1$ y $k = 1$

ii) Determinar el vector $\overline{\mathbf{P}}_k$ de individuos en $\mathbf{P}_{\text{auxiliar}}$ que no son dominados. Este conjunto constituye el frente k . Ignorar este frente en las futuras clasificaciones, esto es $\mathbf{P}_{\text{auxiliar}} = \mathbf{P}_{\text{auxiliar}} - \overline{\mathbf{P}}_k$

iii) Si $k=1$ copiar en $\mathbf{P}_{\text{elite}}$ aquellos individuos que pertenecen al primer frente,
 $\mathbf{P}_{\text{elite}} = \overline{\mathbf{P}}_1$

iv) Hacer $k=k+1$

- v) Realizar la distribución de fitness sobre el conjunto $\overline{\mathbf{P}}_k$ de acuerdo a la ecuación (4.10) y asignar el fitness F . La distancia entre dos individuos cualesquiera se define como la distancia de Hamming
 - vi) Incrementar el fitness ficticio de tal forma que sea el mayor de los fitness en $\overline{\mathbf{P}}_k$:

$$F' = \max \{F(i) / i \in \overline{\mathbf{P}}_k\}$$
 - vii) Si $\mathbf{P}_{\text{auxiliar}} \neq \emptyset$ volver al paso ii), sino parar.
- b) **Elitismo:** éste consiste en la creación y actualización de un conjunto de elite que almacena en cada generación los mejores individuos, es decir aquellas soluciones que pertenecen al primer frente, junto con un mecanismo de decisión que contempla cuales individuos son reinsertados en la población. Los criterios utilizados son los siguientes:
- i) Actualización del conjunto externo: una vez que son incorporados los elementos del primer frente en cada generación, los individuos del conjunto de elite son a su vez clasificados de acuerdo a su dominancia
 - ii) Los individuos no dominados del conjunto de elite pasan a la generación siguiente.
- d) **Selección, cruzamiento y mutación:** se realizan de acuerdo al esquema propuesto en la Sección 4.4.

4.5.3 Ejemplo de Aplicación

A continuación se muestra un ejemplo de aplicación de este método para el proceso de la Figura 4.1 cuando se requiere minimizar el costo de instrumentación y maximizar la confiabilidad total. La formulación del problema es la siguiente:

$$\begin{aligned}
 \text{Max}_q \quad R_s(t) &= \prod_{i=1}^g [1 - pfa_i(t)] q_i \\
 \text{Min}_q \quad CT &= \sum_{i=1}^n c_i q_i \\
 \text{s.t.} \quad & r_B = m
 \end{aligned}
 \tag{4.12}$$

En este ejemplo el espacio de búsqueda es pequeño, existen 56 combinaciones a analizar, de las cuales 32 individuos representan soluciones factibles. En la Tabla 4.4 se listan los parámetros utilizados en el AE.

Parámetro	Valor
Tamaño de la Población	10
Probabilidad de cruzamiento	0.7
Probabilidad de mutación	0.1
r_n	2

Tabla 4.4. Parámetros del AE

La Tabla 4.5 muestra el conjunto Pareto óptimo encontrado

Confiabilidad	Costo	Variables Medidas
0.7101	3500	1, 5, 7
0.7404	4000	2, 5, 7
0.7688	5000	3, 5, 7

Tabla 4.5. Conjunto Pareto óptimo

La Figura 4.2 muestra en el espacio de la función objetivo, la distribución de la población inicial y las soluciones Pareto encontradas; éstas concuerdan con las halladas por búsqueda exhaustiva.

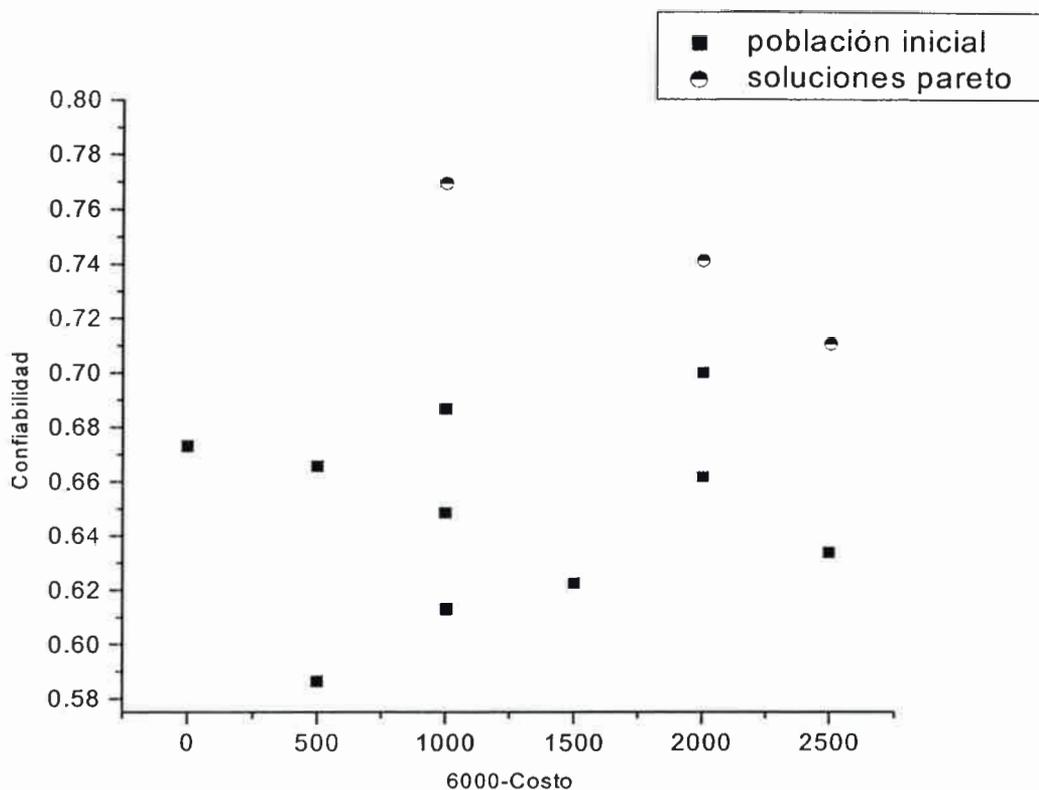


Figura 4.2. Frente pareto óptimo para el ejemplo de la planta de amoniaco

4.6 Conclusiones

En este capítulo se han propuesto nuevas estrategias para la resolución del Diseño de Redes con número mínimo de sensores para una variedad de criterios de desempeño, considerados tanto en forma simple como múltiple.

En el primer caso se utilizaron operadores adecuados junto con búsqueda local incorporada en la mutación. Para el caso multiobjetivo, el algoritmo se modificó en la etapa de asignación de fitness y selección de modo tal de permitir una exploración de diferentes soluciones.

Dada las características que parecen exhibir esta clase de problemas (espacios de búsqueda que crecen exponencialmente con el tamaño del problema; imposibilidad de contar, salvo en casos puntuales, con algoritmos exactos para su resolución; etc.), los AE se presentan como una herramienta robusta para la resolución de los diferentes casos.

Nomenclatura del Capítulo IV

- A Submatriz de **D** correspondiente a las variables medidas
- B Submatriz de **D** correspondiente a las variables no medidas
- b* Número de frentes
- c* Vector de costos de instrumentación
- CT* Costo de capital total
- D** Matriz de incidencia del proceso de dimensión ($m \times n$)
- d* Vector de distancia entre dos soluciones
- E Conjunto de columnas de **D**
- f* Criterio de optimización simple o múltiple
- F* Valor de *fitness*
- F'* Valor de *fitness* ficticio
- g* Número de mediciones de una red de sensores mínima
- GI* Precisión global
- κ Conjunto de posiciones ordinales de unos en \mathbf{q}_1
- L Conjunto de posiciones ordinales de unos en \mathbf{q}_2
- m* Número de ecuaciones del modelo del proceso
- n* Número de variables del modelo del proceso
- nof* Número de criterios de optimización individuales
- P conjunto de soluciones Pareto Óptimas
- pfa** Vector de probabilidad de falla acumulada
- px** Vector de posiciones ordinales de unos en \mathbf{q}
- pu** Vector de posiciones ordinales de ceros en \mathbf{q}
- $\overline{\mathbf{P}}_k$ Soluciones del frente *k*

- q** Vector de variables binarias
- r** Rango matricial
- r_n Radio de nicho
- R_s Confiabilidad del sistema
- R_v Confiabilidad de la estimación de cualquier variable del proceso
- S** Subconjuntos de **E**
- u** Vector de variables no medidas
- w pesos
- x** Vector de variables medidas
- z** Vector de flujos de dimensión n

Letras Griegas

- $\hat{\sigma}_i^2$ Varianza de i -ésima variable estimada
- σ_i^2 Varianza del i -ésimo error de medición
- θ Colección de columnas linealmente independientes de **D**

CAPÍTULO V

DISEÑO DE REDES GENERALES DE SENSORES

5.1 Introducción

En este capítulo se presenta el diseño de una red de sensores de costo mínimo sujeto a restricciones de estimabilidad y precisión sobre un conjunto de variables claves. En contraste con el problema resuelto en el capítulo anterior, se considera aquí un escenario más realista, dado que la observabilidad de todas las variables no medidas del proceso no siempre es requerida.

Resulta un caso de diseño general, en el cual el número de sensores que intervienen en la red no se conoce de antemano. En consecuencia, su resolución matemática es notablemente más compleja que la correspondiente a redes con número mínimo de sensores, y tal lo planteado en el Capítulo 2, sólo instancias de tamaño pequeño pueden resolverse con estrategias de tipo ramificación y acotación. Si el objetivo es encontrar soluciones a problemas de mayor envergadura, entonces las heurísticas aparecen como una alternativa válida. Dentro de éstas, los AE con algunas variantes respecto del AE simple, se han utilizado en problemas de optimización no lineales combinatorios con resultados satisfactorios.

El diseño de redes generales de instrumentos involucra algunos aspectos importantes que condicionan necesariamente el algoritmo a utilizar para su resolución; entre éstos cabe mencionar:

- Necesidad de explorar un espacio de búsqueda de gran tamaño
- Posibilidad de existencia de una superficie de fitness con varios subóptimos
- Necesidad de paralelizar su resolución, con el objeto de reducir los tiempos de computación en problemas muy grandes
- Proveer buenas soluciones alternativas

Estos aspectos dejan fuera de competencia a un AG simple, tal como fuera analizado en el Capítulo 3. Sin embargo, sobre su base puede diseñarse un AE que

considere los aspectos mencionados y sea más eficiente, incluso, que otros métodos de solución.

En este capítulo se formula el problema de diseño de redes generales, se describen los procedimientos utilizados para el cálculo de las restricciones y se presenta una estrategia eficiente de resolución. Esta utiliza un enfoque orientado a las ecuaciones basado en un AE híbrido, con población inicial sembrada y un esquema de selección local basada en el modelo de vecindades.

5.2 Formulación del problema

El diseño de una red de sensores de mínimo costo que satisface las restricciones de estimabilidad y precisión sobre un determinado conjunto de variables claves se formula como sigue:

$$\begin{aligned}
 \underset{q_i}{\text{Min}} \quad & CT = \sum_{i=1}^n c_i q_i \\
 \text{s.t.} \quad & \\
 & E_j \geq 1 \quad \forall j \in K \\
 & \hat{\sigma}_k \leq \hat{\sigma}_k^* \quad \forall k \in P
 \end{aligned} \tag{5.1}$$

siendo: c_i el costo del caudalímetro disponible para medir el flujo i ; \mathbf{q} el vector de variables binarias tal que $q_i = 1$ si z_i es medido y $q_i = 0$ en caso contrario; E_j representa el Grado de Estimabilidad de la variable j (Bagajewicz and Sánchez, 1999) y $\hat{\sigma}_k$ indica el Desvío Estándar de la Estimación de la variable k obtenida después de aplicar un procedimiento de Reconciliación de Datos. Las restricciones de estimabilidad y precisión se imponen sobre los flujos pertenecientes a los subconjuntos K y P , siendo P un subconjunto de K .

Si se denota $A(p)$ al conjunto de todas las posibles combinaciones de p mediciones y $A_l(p)$, al l -ésimo elemento (combinación) de este conjunto; la definición de Grado de Estimabilidad se enuncia a continuación: “una variable j (medida o no) tiene Grado de Estimabilidad E_j si: {resulta estimable después de la eliminación de cualquier combinación $A_l(E_j-1) \in A(E_j-1)$ } y {resulta no observable cuando al menos un conjunto $A_l(E_j) \in A(E_j)$ se elimina}.

Del análisis de la definición anterior surge que, las restricciones impuestas sobre la estimabilidad de las variables claves se satisfacen si éstas son medidas u observables. En consecuencia el análisis de la factibilidad de una solución \mathbf{q} con respecto a la estimabilidad se reduce a determinar si las variables claves no medidas contenidas en \mathbf{q} son observables. Para ello se eligió utilizar un procedimiento de Clasificación de Variables flexible, tal como el basado en factorizaciones ortogonales Q-R (Sánchez y Romagnoli, 1996), que se describe a continuación.

5.2.1 Clasificación de Variables mediante Factorizaciones Ortogonales

Los procedimientos matemáticos de Clasificación de Variables permiten categorizar las variables medidas y no medidas de un proceso teniendo como datos el modelo que representa su operación y un conjunto de instrumentos. Se aplican diferentes estrategias dependiendo de la complejidad matemática del sistema de ecuaciones que constituye el modelo.

Dado el sistema de ecuaciones algebraicas lineales representado por la fórmula 4.1, la descomposición Q-R de la matriz \mathbf{B} (asociada a n_u variables no medidas) permite obtener las matrices \mathbf{Q}_u , \mathbf{R}_u y la matriz de permutación $\mathbf{\Pi}_u$, tal que

$$\mathbf{B} \mathbf{\Pi}_u = \mathbf{Q}_u \mathbf{R}_u, \quad (5.2)$$

a su vez \mathbf{Q}_u y \mathbf{R}_u pueden dividirse en

$$\mathbf{Q}_u = [\mathbf{Q}_{u1} \quad \mathbf{Q}_{u2}] \quad \mathbf{R}_u = \begin{bmatrix} \mathbf{R}_{u1} & \mathbf{R}_{u2} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \quad (5.3)$$

con $r_u = \text{rango}(\mathbf{B}) = \text{rango}(\mathbf{R}_{u1})$. Cabe destacar que \mathbf{Q}_u es una matriz ortogonal y \mathbf{R}_{u1} es una matriz triangular superior de dimensión r_u . De la misma manera las variables no medidas pueden separarse en dos conjuntos

$$\mathbf{\Pi}_u^T \mathbf{u} = \begin{bmatrix} \mathbf{u}_{r_u} \\ \mathbf{u}_{n_u-r_u} \end{bmatrix} \quad (5.4)$$

Premultiplicando el sistema de ecuaciones generales $\mathbf{D} \cdot \mathbf{z} = \mathbf{0}$ por $\mathbf{Q}_u^T = \mathbf{Q}_u^{-1}$ se obtiene

$$\begin{bmatrix} \mathbf{Q}_{u1}^T \mathbf{A} & \mathbf{R}_{u1} & \mathbf{R}_{u2} \\ \mathbf{Q}_{u2}^T \mathbf{A} & \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{x} \\ \mathbf{u}_{r_u} \\ \mathbf{u}_{n_u-r_u} \end{bmatrix} = \mathbf{0} \quad (5.5)$$

Las variables contenidas en el vector \mathbf{u}_{r_u} de dimensión r_u pueden expresarse en función de las demás variables de la siguiente manera

$$\mathbf{u}_{r_u} = -\mathbf{R}_{u1}^{-1} \mathbf{Q}_{u1}^T \mathbf{A} \mathbf{x} - \mathbf{R}_{u1}^{-1} \mathbf{R}_{u2} \mathbf{u}_{n_u-r_u} \quad (5.6)$$

Las siguientes conclusiones surgen del análisis de las ecuaciones anteriores:

Conclusión 1

Si $\text{rango}(\mathbf{R}_u) = r_u = n_u$, siendo n_u el número de variables no medidas, entonces todas las variables no medidas son estimables con las mediciones existentes

Si $\text{rango}(\mathbf{R}_u) = r_u < n_u$, entonces al menos $(n_u - r_u)$ variables no pueden calcularse.

Conclusión 2

Las variables en el subconjunto $\mathbf{u}_{n_u-r_u}$ representan la mínima cantidad y la localización

de las mediciones necesarias para satisfacer la condición de estimabilidad completa del sistema, es decir que todas las variables no medidas sean observables.

➤ Conclusión 3

La matriz Q_{u2}^T obtenida de la factorización Q-R (\mathbf{B}) es tal que

$$Q_{u2}^T \mathbf{B} = \mathbf{0} \quad (5.7)$$

La factorización Q-R de \mathbf{B} da información sobre la factibilidad de calcular las variables no medidas. Las variables contenidas en $u_{n_1-r_1}$ son no observables. Con respecto a las incluidas en u_{r_1} , algunas pueden calcularse directamente utilizando las mediciones disponibles, mientras que otras dependen de los valores de variables en $u_{n_1-r_1}$. Para clasificar las variables en u_{r_1} es necesario inspeccionar las filas de la matriz

$$R_{IU} = R_{u1}^{-1} R_{u2} \quad (5.8)$$

Una variable en u_{r_1} es observable si la correspondiente fila en la matriz R_{IU} es el vector nulo, en caso contrario es no observable.

La clasificación de las *variables medidas* resulta de examinar la matriz G_x

$$G_x = Q_{u2}^T A \quad (5.9)$$

Las columnas de G_x que son vectores nulos representan las variables medidas que no participan en ecuaciones con otras mediciones, por lo tanto corresponden a mediciones no redundantes. Las columnas restantes de G_x están asociadas a las mediciones redundantes.

5.2.2 Cálculo de las Restricciones de Precisión

La precisión de las estimaciones de las variables medidas contenidas en \mathbf{q} se calcula, luego de aplicar el procedimiento de Reconciliación de Datos, como la raíz cuadrada de los elementos de la diagonal de la matriz \mathbf{S}_x ,

$$\mathbf{S}_x = \text{Cov}(\hat{\mathbf{x}}) = (\mathbf{I} - \mathbf{M})\mathbf{S}_y(\mathbf{I} - \mathbf{M})^T, \quad (5.10)$$

siendo $\mathbf{M} = \mathbf{S}_y \mathbf{G}_x^T (\mathbf{G}_x \mathbf{S}_y \mathbf{G}_x^T)^{-1} \mathbf{G}_x$ y \mathbf{S}_y representa la matriz de covarianza de los errores aleatorios de las mediciones, ε , que se suponen tienen una distribución normal con media nula.

De forma análoga, la precisión de las variables no medidas en \mathbf{q} se calculan como la raíz cuadrada de los elementos de la diagonal de la matriz \mathbf{S}_u ,

$$\mathbf{S}_u = \text{Cov}(\hat{\mathbf{u}}) = \mathbf{H} \mathbf{S}_x \mathbf{H}^T, \quad (5.11)$$

siendo $\mathbf{H} = -\mathbf{R}_1^{-1} \mathbf{Q}_1^T \mathbf{A}$.

5.3 Nuevo Algoritmo Evolutivo

A continuación se describe un nuevo procedimiento basado en AE para resolver el problema de diseño de redes generales de sensores.

5.3.1 Justificación de un Algoritmo Evolutivo con Población Estructurada

Los AE son una clase de algoritmos utilizados en optimización que intentan simular la evolución natural. En términos generales los dos principales componentes en un proceso evolutivo son la selección natural y la modificación de material genético en forma aleatoria. La idea de un paisaje adaptivo o superficie de fitness, esto es la representación del fitness como función de todas las posibles combinaciones de material genético, es útil para describir el efecto de estas dos componentes sobre la evolución de las poblaciones.

En un problema de maximización, si la selección domina el proceso, la descendencia de los individuos mejor adaptados (mejores soluciones) tenderá a ser más numerosa, de mejor fitness y a ubicarse en los picos del paisaje. De esta forma, al cabo de varias generaciones, la población se habrá movido hacia un óptimo, no necesariamente global. Si los efectos estocásticos dominan, la población se mueve en forma aleatoria sobre la superficie de fitness.

Los AG tradicionales utilizan esquemas de selección y apareamiento *panmíticos*, ésto es cada individuo compite globalmente con todos los otros presentes en la población. Durante el proceso de selección, un individuo seleccionado puede potencialmente aparearse con cualquier otro individuo en la población. Aunque estos esquemas, tales como selección estocástica con reemplazo, son ampliamente utilizados, se ha llegado a la conclusión que no tienen buen desempeño para realizar búsquedas de genotipos “exitosos” en paisajes adaptivos de gran tamaño y multimodales, tal como los que se encuentran al resolver el problema de diseño planteado (Collins, 1992). Sucede que la población es incapaz de mantener genotipos radicalmente diferentes con buen fitness debido al problema de convergencia prematura. El balance entre explotación y exploración ha sido un tema de análisis constante en los AG tradicionales. En la literatura pueden encontrarse muchas variantes sobre el AG clásico que intentan resolverlo, algunas de las cuales se presentan a continuación.

De Jong (1975) introdujo en los AG un esquema llamado *crowding* (amontonamiento o apiñamiento), en el cual los nuevos individuos (descendencia) reemplazan a los padres que poseen una similaridad genotípica. Sólo una parte de la población se tiene en cuenta al ejecutar las etapas de selección, mutación y cruzamiento.

Otro enfoque es utilizar una función de *sharing*, tal como se introdujo en el capítulo anterior al resolver problemas multiobjetivo, donde la exploración de diferentes zonas del paisaje adaptivo se torna crucial.

Collins, en su trabajo “Estudios sobre Evolución Artificial” enuncia: “*en los procesos naturales no aparecen problemas de convergencia muy difundidos, aún después de billones de años de evolución, la necesidad de métodos especiales para*

evitar la convergencia en AG sugiere que existe un problema básico en la forma en que la evolución está siendo modelada". El método propuesto por Collins se basa en utilizar poblaciones estructuradas, cuyo efecto consiste en dividir a la población en subpoblaciones genéticamente independientes. Aún cuando el proceso de evolución conduzca a que cada subpoblación local se localice alrededor de un sub-óptimo, cada una podría fijarse en un genotipo diferente, manteniendo diversidad en la población considerada como un todo. En otras palabras descentralizar una población simple en varias subpoblaciones, permite un mejor muestreo del espacio de búsqueda y mejora el comportamiento del algoritmo básico tanto en calidad de soluciones como en tiempos de ejecución (Alba y co., 2002).

En la bibliografía se han propuesto varios modelos de poblaciones estructuradas usualmente categorizados como modelos de islas o modelos de vecindades.

En el primero, conocido como AEs distribuidos, la población se divide en varias subpoblaciones sobre las que se ejecutan AEs independientes, que cooperan entre si a través de un mecanismo denominado migración. El rol de la migración es intercambiar información (por ejemplo por cruzamiento) entre una isla y otra; la cantidad de individuos migrados (velocidad) y la frecuencia de migración determinan la cantidad de información intercambiada.

En el segundo modelo, conocido como AEs celulares, el intercambio de información entre los individuos está restringido a una estructura de vecindad local. Esto es, un individuo dado tiene su propio conjunto de compañeros potenciales de apareamiento definido por la vecindad del individuo; al mismo tiempo un mismo individuo pertenece a varios conjuntos de apareamiento. Con el objetivo de simular una topología del espacio de búsqueda determinada, los individuos se distribuyen en una grilla unidimensional (anillo) o bidimensional (toroide) (Sarma y co., 1997). El solapamiento de las vecindades permite una difusión uniforme de las buenas soluciones a través de la grilla.

La Figura 5.1 (Alba y co., 2002) ilustra esquemáticamente el modelo panmítico junto con los modelos de islas y de vecindades.

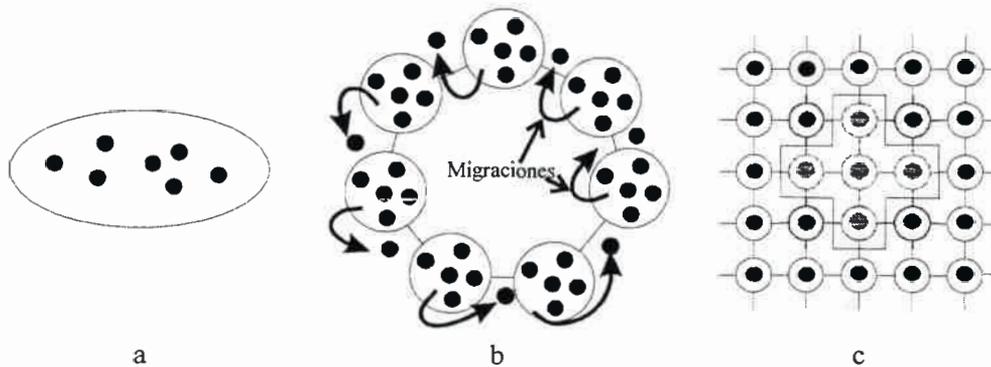


Figura 5.1. a) modelo panmítico; b) modelo de islas; c) modelo de vecindades

En conclusión las características y diferencias de esos tres modelos puede resumirse como sigue:

- En el modelo panmítico todos los individuos están en la misma población, la cual, generalmente es de mayor tamaño. Cada individuo puede interactuar con cualquiera de los otros.
- El modelo de islas mantiene más de una población de menor cantidad de individuos que en el modelo anterior, los individuos interactúan dentro de cada isla y la interacción entre islas se realiza a través del mecanismo de migración.
- El modelo de vecindades locales puede pensarse como micro poblaciones cuyo tamaño está dado por la cantidad de vecinos de cada individuo y la interacción entre las vecindades se permite por la pertenencia de cada individuo a varias vecindades.

Una vez que ha sido diseñado un modelo de población estructurada, éste puede ser implementado tanto en una máquina con un solo procesador, como en un hardware en paralelo. Si bien un AE canónico es intrínsecamente paralelizable, existe una larga tradición en utilizar este modelo en las implementaciones en paralelo. Esto resulta atractivo si se tiene en cuenta su aplicabilidad a la resolución de problemas combinatorios de gran tamaño, como el diseño de instrumentación en plantas de gran escala, ya que suministran un mejor muestreo del espacio de búsqueda, a la vez que reducen los tiempos de ejecución.

Para la resolución del problema planteado en este capítulo se utilizó una población descentralizada en forma de vecindades unidimensionales, implementada en forma secuencial.

5.3.2 Diseño del Algoritmo Evolutivo

5.3.2.1 Generación de la Población Inicial

La generación de la población inicial puede realizarse al azar, como en un AG clásico. Sin embargo el conocimiento específico del problema permite construir una población inicial de mejor calidad, lo cual contribuye a mejorar la futura evolución.

En este trabajo se optó por generar la población inicial dentro del espacio de soluciones factibles desde el punto de vista de la estimabilidad (Carnero y co., 2002). Para ello fue necesario implementar un algoritmo que se describe a continuación.

Cada solución se representa por medio de una matriz \mathbf{T} de dimensión $[rv \times (m+1)]$, donde rv es el número de variables requeridas y m representa el número de filas de la matriz de incidencia \mathbf{D} .

Las primeras m columnas de \mathbf{T} contienen la posición ordinal en \mathbf{D} , de la ecuación o combinaciones de ecuaciones que son usadas para el cálculo de cada variable requerida. En caso de ser necesario, se agregan ceros hasta completar las m columnas. La última columna de \mathbf{T} corresponde al Índice de Medición, MI , que es una variable aleatoria discreta asociada a cada variable requerida. Los valores asumidos por esta variable pueden ser 1, si corresponde a una variable medida no redundante, 0 si es una variable no medida y -1 si corresponde a una variable medida redundante.

Una convención especial se ha adoptado para escribir la posición ordinal en \mathbf{D} correspondiente a las ecuaciones involucradas en el cálculo de una variable requerida. Para cada fila de \mathbf{T} , el primer lugar es ocupado por la posición ordinal de la ecuación con coeficiente distinto de cero. Los otros lugares se completan con las posiciones ordinales de las ecuaciones con coeficientes cero y los restantes lugares con ceros.

Para ilustrar la representación de una solución, considérese que las variables z_2 y z_4 son las variables requeridas en el diagrama de flujo representado por la matriz de incidencia \mathbf{D} ,

$$\mathbf{D} = \begin{bmatrix} 1 & -1 & 0 & -1 & 0 & 0 \\ 0 & 1 & -1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & -1 & 0 \end{bmatrix}$$

La variable z_2 aparece con coeficientes distintos de cero en las filas 1 y 2. Por lo tanto z_2 puede ser calculada de cuatro maneras diferentes: a) utilizando la ecuación 1 b) utilizando la ecuación 2 c) utilizando una combinación de las ecuaciones 1 y 3 d) utilizando una combinación de las ecuaciones 2 y 3. Considérese la siguiente solución

	Ecuación 1	Ecuación 2	Ecuación 3	<i>MI</i>
z_2	1	3	0	1
z_4	1	2	0	0

Esto significa que la variable requerida z_2 se calcula a través de la combinación lineal de las ecuaciones 1 y 3, en tanto que la variable requerida z_4 se estima utilizando la combinación lineal de las ecuaciones 1 y 2. La última columna del arreglo indica que z_2 y z_4 son consideradas variable medida no redundante y variable no medida respectivamente.

La calidad de la población inicial puede mejorarse al considerar que la variable aleatoria discreta *MI* asume un valor -1. Esto permite introducir variables medidas redundantes en la primera generación. Más aún, se consideran altas probabilidades para el evento $MI = -1$ con el objeto de incrementar la redundancia y consecuentemente la precisión.

El tamaño máximo de la población está dado por el número total de combinaciones entre los $(2^{m-1} r_v)$ subconjuntos de ecuaciones que pueden ser utilizadas para calcular las variables requeridas y los tres resultados posibles de la variable *MI*.

Para generar una solución inicial factible se aplica el siguiente procedimiento para cada variable requerida p ($p=1, \dots, rv$).

Definir $I = \{1, \dots, m\}$.

Definir O como el conjunto de los elementos de I que corresponden a las filas de D con entradas distintas de cero para la variable p . A lo sumo dos elementos de I satisfacen esta condición.

Seleccionar el primer bit de la fila (t_{pi}). Si O tiene dos elementos se selecciona uno de ellos en forma aleatoria y se considera $a = 2$. En caso contrario, el único elemento de O constituye el primer bit y $a=1$.

Definir $I' = I - O$

Inicializar $t_{pw} = 0$, con $w = 2, \dots, m$

Generar t_{pw} con $w = 2, \dots, m$; Se selecciona una combinación del conjunto $\binom{|I'|}{b}$, $b \in \{0, 1, \dots, |I'|\}$ usando un procedimiento aleatorio. Primero se genera un valor de b y luego se obtiene un conjunto de cardinalidad b de los elementos de I' , con la siguiente metodología:

Cada ecuación se incluye en forma secuencial en la combinación propuesta, si entre las variables que participan, existe al menos una que tenga coeficiente de distinto signo en las respectivas ecuaciones. Esto impide que una ecuación sólo introduzca variables sin quitar ninguna otra. Esto es, si CL^j es el conjunto de variables de la combinación lineal actual, entonces la ecuación $i \in I'$ se adiciona a la combinación lineal para dar CL^{j+1} si $CL^{j+1} \not\subset CL^j$.

Seleccionar aleatoriamente los valores de MI .

Cada solución inicial factible se codifica en un vector binario, \mathbf{q} , que representa una propuesta de instrumentación. Esto se realiza a través del siguiente procedimiento:

Inicializar el vector de variables medidas (\mathbf{q}) y el vector de memoria (\mathbf{mem}) como vectores nulos. Ambos vectores son de dimensión n , el primero tiene sus componentes iguales a 1 para las variables medidas mientras que el segundo tiene sus componentes en 1 si la variable correspondiente es medida o estimable.

Repetir para cada variable p ($p=1\dots, rv$) perteneciente a vector \mathbf{req} (variables requeridas)

i) Si $MI(p)=1$, la variable es medida y no redundante, el elemento del vector \mathbf{q} que corresponde a $\mathbf{req}(p)$ es igual a 1, esto es $\mathbf{q}(\mathbf{req}(p)) = 1$

ii) Si $MI(p)=0$, la variable es no medida, entonces su valor será calculado usando la combinación lineal propuesta en el cromosoma. En este caso, las variables que participan en la ecuación resultante, excepto p , deberían ser medidas e incluidas en \mathbf{q} . El vector \mathbf{mem} se actualiza incorporando tanto las nuevas variables medidas como las estimables.

Si $MI(p)=-1$, la variable es redundante (medida y estimable), los procedimientos i) e ii) se aplican simultáneamente.

hasta que el vector \mathbf{mem} contenga unos en las posiciones correspondientes a todas las variables requeridas.

5.3.2.2 Función de aptitud

El cálculo de la función de aptitud o fitness para cada solución \mathbf{q} se realiza considerando el costo de cada variable medida y la violación a las restricciones como sigue:

$$fitness(\mathbf{q}) = \sum_{i=1}^n c_i q_i + \rho \quad (5.12)$$

donde ρ es la función de penalización aplicada a las soluciones no factibles. Se considera que ρ es cero si no ocurre una violación. En caso contrario se asumió para ρ un valor igual al máximo costo de instrumentación, que constituye un límite superior para los posibles valores de la función objetivo. Posteriormente la selección realizará, además, un *ranking* de los valores de la función objetivo para conformar el conjunto de apareamiento.

5.3.2.3 Operadores genéticos

Los operadores genéticos son los encargados de modificar la población y conducir la evolución. Se analizan a continuación los métodos de selección, cruzamiento y mutación utilizados en este trabajo.

a) Selección

En un AE equipado con selección local, el intercambio de información entre los individuos está restringido a una estructura de vecindad local. Con el objetivo de simular una topología del espacio de búsqueda determinada, los individuos se distribuyen usualmente en una grilla unidimensional (anillo) o en un toroide bidimensional.

En este trabajo se utilizó una estrategia de selección local basada en una vecindad lineal, en la cual cada individuo tiene una vecindad dada por los ν individuos que lo preceden o suceden. Así un individuo k tiene $k-\nu$ precedentes y $k+\nu$ sucesores. En los extremos, algunos vecinos corresponderán al extremo opuesto.

El método define, en primer lugar, un conjunto de individuos que son seleccionados para ser "padres"; el mecanismo de selección utilizado es el método de muestreo estocástico universal aplicado a una población de individuos todos con igual probabilidad de ser seleccionados, con el objeto de distribuir uniformemente los individuos padres. La selección de las "madres" o compañeros de apareamiento se realiza, para cada padre, entre los individuos de su vecindad. Para evitar diferencias desproporcionadas en los valores de *fitness*, se somete a la población a un *ranking* lineal antes de comenzar el proceso. De esta manera los cromosomas son seleccionados proporcionalmente a su rango más que a los valores reales de la función de aptitud, de acuerdo a la expresión 3.5. Así se evita que superindividuos eliminen material genético deseable y hagan que la evolución converja prematuramente (Michalewicz, 1996).

Como ejemplo, considérese una población formada por once individuos cuyos valores de *fitness* y probabilidad de selección p_s , luego de aplicar *ranking* lineal utilizando la ecuación 3.5 con un parámetro $\eta_{max} = 1.3$, se muestran en la Tabla 5.1.

Individuo	Cromosoma	<i>Fitness</i>	p_s
1	11111110	11500	0.0909
2	10000101	5000	0.1182
3	11010110	7500	0.1073
4	10100101	7500	0.1073
5	01010111	8000	0.1018
6	11010110	7500	0.1073
7	01011110	8000	0.1018
8	11100100	7500	0.1073
9	11010010	18000	0.0636
10	00011110	6500	0.1073
11	01010110	6500	0.1073

Tabla 5.1. Población inicial para el ejemplo de la planta de amoníaco

Nº Individuo
1
3
5
7
10

Tabla 5.2 Individuos seleccionados como padres.

La Tabla 5.2 contiene los individuos que fueron seleccionados como padres tomando un tamaño de vecindad $v = 6$. Estas se presentan en la Tabla 5.3.

Predecesores	N° Ind	Sucesores
9, 10, 11	1	2, 3, 4
11, 1, 2	3	4, 5, 6
2, 3, 4	5	6, 7, 8
4, 5, 6	7	8, 9, 10
7, 8, 9	10	11, 1, 2

Tabla 5.3. Vecindades de cada individuo de la población seleccionada.

Considerando la vecindad del primer individuo, puede observarse que el individuo 2 es el que posee mayor probabilidad de ser seleccionado como compañero de apareamiento del cromosoma 1. El procedimiento de selección para conformar el *pool* de apareamiento arroja los resultados que se muestran en la Tabla 5.4.

Padre	Madre
1	2
3	2
5	2
7	10
10	2

Tabla 5.4 Padres y madres seleccionados.

Finalmente, la población seleccionada se dispone en un vector cuyas componentes impares corresponden a los padres y las componentes pares a las madres. Esta es la población que será sometida a la acción de los operadores genéticos de cruzamiento y mutación. Una vez realizadas dichas modificaciones se realizará la inserción de los individuos en la población original.

La reubicación de la descendencia se realiza de forma tal de respetar las vecindades de los progenitores e incorporar elitismo al algoritmo, capturando buenas soluciones que permanecerán en las sucesivas generaciones.

El procedimiento de selección local puede esquematizarse como sigue:

- Para cada individuo i_i seleccionado como padre, se elige como compañero de apareamiento el mejor vecino i_j ,
- Se someten ambos a cruzamiento y mutación para dar lugar a la descendencia i_i' e i_j' .
- Si el *fitness* de i_i' es mejor que i_i se reemplaza i_i por i_i' . De igual manera si el *fitness* de i_j' es mejor que i_j se reemplaza el hijo en el lugar del progenitor.

b) Cruzamiento

El operador de cruzamiento es el encargado de intercambiar “material genético” entre dos individuos. Se utilizó, en este trabajo cruzamiento uniforme, en el cual cada bit es copiado desde el padre o la madre de acuerdo con una máscara de bits generados en forma aleatoria. Los progenitores son tomados del vector de salida del procedimiento de selección.

c) Mutación

El operador mutación permite la inclusión de elementos diferentes a los existentes en la población actual. En este trabajo se utilizó un operador de mutación estándar.

5.3.2.4 Procedimiento de búsqueda local

Cuando se dispone de información específica del problema a resolver, ésta puede ser utilizada para implementar una técnica de búsqueda local que trabaje conjuntamente con el AG. Este método, conocido como hibridización, permite explotar la perspectiva global del AE y la convergencia que aporta la técnica de búsqueda específica (Goldberg, 1989).

Dicha implementación puede ser llevada a cabo de diferentes formas, puede por ejemplo, permitirse que el AE se ejecute hasta alcanzar cierto grado de convergencia y entonces realizar la optimización local sobre un cierto porcentaje (usualmente del 5 al

10%) de la población en la última generación. Otra alternativa es seleccionar de la población corriente uno o más de los mejores individuos, aplicar la búsqueda local sobre ellos e insertarlos nuevamente en la población para continuar con la optimización genética normal.

El procedimiento de búsqueda local implementado en este capítulo utiliza esta última alternativa, seleccionando el 5 % de los individuos mejor adaptados y que representan soluciones factibles desde el punto de vista de la estimabilidad.

El entorno para una solución particular, donde se lleva a cabo la optimización local, está definido como el conjunto de soluciones que se encuentran a una distancia de Hamming menor o igual que 2 (dos). El algoritmo de búsqueda local inspecciona el entorno, con el objetivo de encontrar una solución de mejor fitness, evaluando dos alternativas: la posibilidad de intercambiar una variable medida con una no medida (distancia de Hamming=2) o la de eliminar una variable medida del conjunto de mediciones sin reemplazarla (distancia de Hamming=1).

Dicha inspección se realiza utilizando el procedimiento de clasificación de variables de la forma que se describe a continuación (Carnero y co., 2004).

Dada una solución \mathbf{q}_0 la ecuación 5.6 permite expresar el vector de variables no medidas de la siguiente forma:

$$\mathbf{u}_{r_i} = -\mathbf{R}_{u1}^{-1} \mathbf{Q}_{u1}^T \mathbf{A} \mathbf{x} - \mathbf{R}_{u1}^{-1} \mathbf{R}_{u2} \mathbf{u}_{n_i-r_i} = \mathbf{C} \mathbf{x} - \mathbf{R}_{IU} \mathbf{u}_{n_i-r_i}$$

Las matrices \mathbf{C} y \mathbf{R}_{IU} contienen la información necesaria para determinar el par de variables medidas y no medidas pertenecientes a \mathbf{q}_0 que pueden ser intercambiadas mientras se preserva la observabilidad de las variables requeridas: “*Un par de variables (u_i, x_j) pueden ser intercambiadas si el coeficiente $c_{ij} \neq 0$ y la correspondiente fila i de \mathbf{R}_{IU} es nula*”.

Por otra parte, si una columna de la matriz \mathbf{C} resulta nula implica que la correspondiente variable medida no participa en el cálculo de las variables no medidas

corrientes y puede por lo tanto ser extraída del conjunto de mediciones a la vez que se mantiene la estimabilidad de las variables claves: “Una variable medida x_j puede pasar a no medida si la correspondiente columna j de la matriz \mathbf{C} es nula ”.

Como ejemplo, considérese una matriz \mathbf{D} de tamaño (5x8)

$$\mathbf{D} = \begin{bmatrix} -1 & 0 & 0 & 0 & 0 & 1 & 0 & 1 \\ 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & -1 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & -1 & -1 \end{bmatrix}$$

El conjunto de variables requeridas sujetas a restricciones de estimabilidad es $K = \{z_1, z_2, z_6\}$. Supóngase una solución $\mathbf{q}_0 = [1 \ 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1]$ de la población seleccionada. El procedimiento de clasificación de variables arroja como resultado que las variables no medidas correspondientes a los flujos z_3 y z_6 son determinables con la instrumentación propuesta, de acuerdo a la siguiente expresión:

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & -1 \\ 0 & 1 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} - \begin{bmatrix} 0 \\ -1 \\ 0 \\ 1 \end{bmatrix} [u_5]$$

donde u_1 corresponde al flujo z_3 , u_2 al flujo z_4 , u_3 al flujo z_6 , u_4 al flujo z_5 , u_5 al flujo z_7 , x_1 al flujo z_1 , x_2 al flujo z_2 y x_3 al flujo z_8 .

Puede observarse que los intercambios factibles son (x_1, u_3) , (x_2, u_1) , y (x_3, u_3) . Cada intercambio origina una nueva propuesta de medición donde se preserva la observabilidad de las variables requeridas y constituyen el entorno $E(\mathbf{q}_0)$ de la solución dada. Para este caso la matriz \mathbf{C} no tiene columnas nulas y por lo tanto no es factible eliminar ninguna variable medida del conjunto de mediciones.

El algoritmo general de búsqueda local utiliza la subrutina *mejorar* que consiste en realizar los intercambios de acuerdo al siguiente esquema:

$$\text{mejorar}(\mathbf{q}_0) = \begin{cases} \text{cualquier } \mathbf{q} \in E(\mathbf{q}_0) \text{ con } \textit{fitness}(\mathbf{q}) < \textit{fitness}(\mathbf{q}_0) \\ \text{"no" caso contrario} \end{cases}$$

Dicho algoritmo se presenta a continuación:

```

/*****
/* Algoritmo de búsqueda local*/
/*****
comenzar
  q0 := solución inicial
  mientras mejorar(q0) ≠ 'no' hacer
    q0 := mejorar(q0)
  retornar q0
fin

```

5.3.3 Ejemplos y Resultados

El AE descrito anteriormente fue aplicado al diseño de una red de sensores para la planta de amoníaco simplificada presentada en el Capítulo IV. El proceso involucra cinco unidades y ocho corrientes, por lo tanto cada solución es codificada con un cromosoma de ocho bits. Si bien este ejemplo representa una instancia del problema propuesto de tamaño pequeño, este se utilizó como problema verificación para permitir la comparación de los resultados obtenidos con un algoritmo de búsqueda tipo rama y acotación.

El conjunto de variables requeridas sujetas a restricciones de estimabilidad es $K = \{z_1, z_2, z_6\}$, el subconjunto $P = \{z_2, z_6\}$ corresponde a las variables sujetas también a restricciones de exactitud. La Tabla 5.5 muestra el costo de los instrumentos disponibles, su desvío estándar y los límites superiores sobre el desvío estándar de las variables claves, expresados en porcentaje del valor verdadero de los flujos.

Los parámetros del AE se muestran en la Tabla 5.6, mientras que los resultados de la optimización se presentan en la Tabla 5.7. La mejor solución obtenida mediante la técnica propuesta corresponde al óptimo global encontrado utilizando el método de

rama y acotación presentado en el Apéndice de este capítulo.

Corriente	Flujos	Costo	σ	σ^*
1	1000	1000	3%	
2	1000	1500	2%	1.5%
3	1000	2500	1.5%	
4	600	1500	2%	
5	400	1500	2%	
6	550	2500	1.5%	1.5%
7	150	1000	3%	
8	450	1500	2%	

Tabla 5.5. Datos del ejemplo

Parámetro	Valor
Tamaño de la población	11
Probabilidad $MI = -1$	0.4
Probabilidad $MI = 1$	0.3
Método de Selección	Selección local
Presión selectiva	1.3
Tamaño de la vecindad	3
Probabilidad de Mutación	0.01
Probabilidad de cruzamiento	0.7
Número de generaciones	20

Tabla 5.6 Parámetros del AE

Nro. de Sensores	2
Localización Óptima	6, 8
Desvío Estándar de las estimaciones de las variables	$\hat{\sigma}_2 = 1.22$ $\hat{\sigma}_6 = 1.5$
Costo	\$ 4000

Tabla 5. 7. Resultados de la optimización para el ejemplo propuesto

5.4 Conclusiones

En este capítulo se analizó el diseño de redes de sensores para el caso más general. El enfoque propuesto para el modelado matemático del problema no admite expresar las restricciones de estimabilidad y precisión como una función explícita de las variables binarias, ya que las dimensiones de las matrices involucradas en el modelo del proceso dependen del conjunto de mediciones propuesto, es decir del vector binario \mathbf{q} . De acuerdo a la clasificación propuesta por Nemhauser (Nemhauser, 1999), esto implica que el problema así modelado sea clasificado como uno de optimización combinatoria genérico y no como uno de programación no lineal mezcal entera (MINLP).

Dada las características complejas del problema planteado y la necesidad de resolver instancias del mismo que representen plantas de tamaño real, se propuso como técnica de resolución un AE híbrido, con población inicial sembrada y operadores genéticos adecuados, haciéndose especial énfasis en la estructura espacial de la población y en el operador de selección, así como en la posibilidad de su implementación en paralelo casi en forma directa.

Nomenclatura del Capítulo V

- $A(p)$ Conjunto de todas las posibles combinaciones de p mediciones
- A** Submatriz de **D** correspondiente a variables medidas
- B** Submatriz de **D** correspondiente a variables no medidas
- c** Vector de costos de instrumentación.
- CT** Costo de capital total
- D** Matriz de incidencia del proceso de dimensión $(m \times n)$
- E** Entorno de una solución
- E_j Grado de estimabilidad de la variable j
- F** Valor de *fitness*
- i** Individuo
- K** Conjunto de variables de proceso sujetas a restricciones de estimabilidad
- m Número de ecuaciones del modelo del proceso
- mem** Vector de memoria
- MI** Índice de Medición
- n Número de variables del modelo del proceso
- P** Conjunto de variables de proceso sujetas a restricciones de precisión
- q** Vector de variables binarias
- r** Rango matricial
- req** Vector de variables requeridas
- rv Número de variables requeridas
- S_u** Matriz de covarianza de las estimaciones de las variables no medidas
- S_x** Matriz de covarianza de las estimaciones de las variables medidas
- S_y** Matriz de covarianza de los errores aleatorios de las mediciones

- T** Matriz de representación de soluciones
- u** Vector de variables no medidas
- x** Vector de variables medidas
- z** Vector de flujos de dimensión n

Letras Griegas

- ε Vector de errores aleatorios de las mediciones
- σ_i Desviación estándar del i -ésimo error de medición
- $\hat{\sigma}_k$ Desviación estándar k -ésima variable estimada
- ν Tamaño de vecindad
- ρ Función de penalización

APÉNDICE CAPITULO V

Técnicas de enumeración implícitas: algoritmo de *branch and bound*

El método de ramificación y acotación o *branch and bound* se basa en la enumeración inteligente de todas las soluciones posibles en un problema de optimización combinatoria.

La implementación de un método de estas características requiere que el problema particular a resolver exhiba dos condiciones:

- Un conjunto de soluciones, representadas por un nodo, puede particionarse en subconjuntos mutuamente excluyentes. Cada uno de estos subconjuntos son denominados hijos del nodo original. El término ramificación está referido a estas particiones sucesivas del espacio de soluciones
- Se debe contar con un algoritmo para el cálculo de un límite inferior sobre el costo de cualquier solución en un subconjunto dado. Estos límites inferiores (acotación) son utilizados para construir una prueba de optimalidad sin inspección exhaustiva de todo el espacio de búsqueda.

A continuación se muestra el pseudocódigo utilizado para resolver el ejemplo de una red de amoníaco utilizando una estrategia de ramificación y acotación.

```
/* **** */
/* Algoritmo Branch and Bound utilizado para resolver el */
/* ejemplo de una red de amoníaco */
/* **** */

Inicio
Conjuntoactivo:={0} /* ninguna corriente es medida*/
Niveles:={0} /* Nodo raiz=>nivel 0 */
U:=10000 /* Limite superior del costo */
Mejor:=0 /* Mejor solucion encontrada */
k=0
```

```
mientras conjunto activo no es vacío hacer
  nodo:=conjuntoactivo(1)
  nivel:=niveles(1)
  remover nodo k de Conjuntoactivo
  generar hijos del nodo k (h) y su costo (z)
  para i=1: numero de hijos del nodo k
    si z(i)>=U
      descartar h(i)
    sino-si h(i) es una solucion factible
      U:=z(i)
      Mejor:=h(i)
    sino
      Setactivo:={setactivo U h(i)}
      Niveles.={niveles U (nivel+1)}
  Fin
Fin
Fin
```

CAPÍTULO VI

EJEMPLOS DE APLICACIÓN

6.1 Introducción

Este capítulo contiene ejemplos de diseño de redes de sensores para el sistema de vapor de una planta de producción de metanol presentado por Serth y Heenan (1986). Este proceso consta de 28 corrientes y 11 equipos. Los ejemplos consideran que los sensores pueden ubicarse sobre cualquier corriente, suposición que aumenta el número de combinaciones a evaluar por el algoritmo de resolución. El espacio de búsqueda para este problema es $2^{28}=268.435.456$ combinaciones posibles.

Se presentan diferentes casos de diseño resueltos mediante los AE propuestos en esta tesis. En primera instancia se analiza el diseño óptimo de redes con número mínimo de sensores, considerando criterios de optimización simples y múltiples. Posteriormente se discute el desempeño de la estrategia evolutiva para diseño de redes generales de sensores, considerando casos con requerimientos cada vez mayores en la cantidad de variables claves.

6.2 Descripción del Proceso

El diagrama de flujo del sistema de vapor de la planta de producción de metanol se presenta esquematizado en la Figura 6.1. Además en la Tabla 6.1 se muestran los valores verdaderos de los caudales máxicos, C^m_i , para cada corriente del proceso expresados en tn/h y la probabilidad de falla acumulada, pf_{a_i} , el desvío estándar del error de la medición y el costo de cada instrumento de medición disponible para medir el correspondiente caudal. Esta información se extrajo del trabajo de Sen y co. (1998).

Corriente	C_i^m	pf	σ_i	c_i
1	0.86	0.141	0.0215	3.7
2	1.	0.174	0.025	4.5
3	111.82	0.104	2.8	132.2
4	109.95	0.07	2.749	129.2
5	53.27	0.174	1.332	65.3
6	112.27	0.096	2.807	132.4
7	2.32	0.164	0.058	5.0
8	164.05	0.165	4.101	193.9
9	0.86	0.055	0.0215	2.06
10	52.41	0.099	1.31	62.8
11	14.86	0.153	0.3715	20.2
12	67.27	0.092	1.682	80.0
13	111.27	0.052	2.782	130.4
14	91.86	0.154	2.296	109.8
15	60.	0.095	1.5	71.6
16	23.64	0.116	0.591	29.7
17	32.73	0.077	0.8182	39.5
18	16.23	0.08	0.4057	20.4
19	7.95	0.099	0.1987	11.1
20	10.5	0.074	0.2625	13.6
21	87.27	0.071	2.182	102.9
22	5.45	0.094	0.1362	8.1
23	2.59	0.170	0.0648	6.3
24	46.64	0.066	1.166	55.5
25	85.45	0.088	2.136	101.0
26	81.32	0.143	2.033	93.7
27	70.77	0.128	1.769	84.7
28	72.23	0.075	1.806	85.4

Tabla 6.1. Datos para el sistema de vapor de una planta de producción de metanol

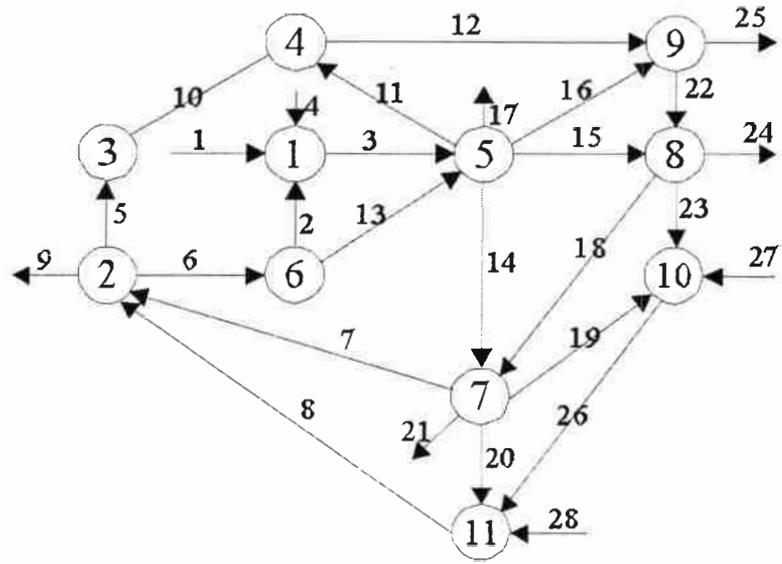


Figura 6.1. Diagrama de Flujo del Sistema de Vapor de la Planta de Producción de Metanol

6.3 Caso 1

En este punto se presentan los resultados obtenidos utilizando técnicas evolutivas, para el caso del diseño de redes de sensores con número mínimo de instrumentos y un objetivo simple a optimizar. En la Tabla 6.2 se muestran los valores de los parámetros empleados por el AE.

En primer lugar los criterios de desempeño analizados son la precisión global (GI) y la mínima confiabilidad asociada a una variable ($\text{Min } R_v$). En el caso de la precisión global sólo se presenta un óptimo, mientras que para el segundo criterio aparecen cinco soluciones óptimas diferentes. Todas las soluciones encontradas coinciden con las obtenidas utilizando un enfoque orientado a grafos (Sen y co., 1998). En la Tabla 6.3 se incluye el conjunto óptimo de variables medidas, así como el valor de la función objetivo en la solución.

En segundo lugar se analizó el comportamiento del AE cuando las funciones objetivo son el costo de adquisición de los instrumentos (CT) y la confiabilidad asociada a la red de sensores (R_s). A pesar que las características de estas formulaciones de diseño permiten resolverlo exactamente mediante el Algoritmo Goloso, se realizaron

corridas con estos criterios de optimización para verificar la robustez del AE propuesto con diferentes funciones objetivo. Los resultados también se presentan en la Tabla 6.3 y coinciden con los obtenidos por métodos exactos. En ambos casos las funciones objetivos exhiben un único óptimo global.

En la Tabla 6.4 se muestran todos los valores alcanzados por las diferentes funciones objetivo para cada criterio de optimización. Dado este conjunto particular de datos, puede observarse que existen conflictos entre los diferentes objetivos, excepto para el caso del costo y la precisión global. Por ejemplo, para una red no redundante el costo mínimo encontrado es $CT = \$ 555.5$, a este diseño le corresponde una confiabilidad $R_s = 0.141$, mientras que $R_s = 0.235$, casi el doble, para el diseño de la red más confiable con un costo de $\$ 1178.2$. El mismo análisis puede hacerse para CT versus R_s .

Parámetro	Valor
Tamaño de la Población	50
Probabilidad de cruzamiento	0.7
Probabilidad de Mutación	0.05
Número de generaciones	100

Tabla 6.2. Parámetros para el AE.

Criterio	Función Objetivo	Variables Medidas
GI	85.00	1 2 7 9 10 11 16-24 27 28
R_v	0.5282	3 4 5 8 9 10 13 15 16 17 22-28
		3 4 6 8 9 10 11 13 15 17 22-28
		3 4 6 8 9 10 12 13 15 17 22-28
		3 4 6 8 9 10 13 15 16 17 22-28
		1 3 4 8 9 10 11 13 15 17 22-28
CT	555.5	1 2 7 9 10 11 16-24 27 28
R_s	0.235	3 4 6 9 10 12 13 15 17 -22 24 25 28

Tabla 6.3. Resultados de la optimización

	GI	R_v	CT	R_s
GI	85	0.265	555.5	0.141
R_v	245.9	0.528	1291.3	0.151
	278.8		1349.0	0.116
	285.2		1408.8	0.124
	282.3		1358.5	0.137
	231.8		1220.3	0.110
CT	85	0.265	555.5	0.141
R_s	268	0.376	1178.2	0.235

Tabla 6.4. Valores alcanzados por las diferentes funciones objetivo.

6.4 Caso 2

En esta sección se presentan los resultados del diseño de redes de sensores con número mínimo de instrumentos cuando se consideran simultáneamente dos criterios a optimizar, en particular el costo y la confiabilidad total de la red. Se utiliza como método de resolución el algoritmo para diseño óptimo multiobjetivo detallado en el Capítulo 4.

En la Tabla 6.5 se muestran los valores de los parámetros empleados por el AE, mientras que la Tabla 6.6 contiene las soluciones encontradas correspondientes al mejor frente Pareto obtenido.

Parámetro	Valor
Tamaño de la población	50
Probabilidad de cruzamiento	0.7
Probabilidad de mutación	0.10
r_n	4

Tabla 6.5. Parámetros empleados por el algoritmo

R_s	CT	Variables medidas
0.1410	555.5	1 2 7 9 10 11 16 17 18 19 20 21 22 23 24 27 28
0.1421	572.7	1 2 7 9 11 12 16 17 18 19 20 21 22 23 24 27 28
0.1427	593.7	1 2 7 9 11 16 17 18 19 20 21 22 23 24 25 27 28
0.1504	600.0	1 2 4 7 9 10 11 16 17 18 19 20 21 22 23 24 28
0.1533	601.2	1 2 7 9 10 11 13 16 17 18 19 20 21 22 23 24 28
0.1545	618.4	1 2 7 9 11 12 13 16 17 18 19 20 21 22 23 24 28
0.1549	638.0	1 2 7 9 11 12 15 16 17 18 19 20 21 22 24 27 28
0.1552	639.4	1 2 7 9 11 13 16 17 18 19 20 21 22 23 24 25 28
0.1556	659.0	1 2 7 9 11 15 16 17 18 19 20 21 22 24 25 27 28
0.1612	659.8	1 2 4 7 9 10 12 16 17 18 19 20 21 22 23 24 28
0.1612	659.8	1 2 4 7 9 10 12 16 17 18 19 20 21 22 23 24 28
0.1643	661.0	1 2 7 9 10 12 13 16 17 18 19 20 21 22 23 24 28
0.1671	666.5	1 2 7 9 10 11 13 15 16 17 18 19 20 21 22 24 28
0.1684	683.7	1 2 7 9 11 12 13 15 16 17 18 19 20 21 22 24 28
0.1692	704.7	1 2 7 9 11 13 15 16 17 18 19 20 21 22 24 25 28
0.1718	724.1	1 2 4 7 9 10 11 13 16 17 18 19 20 21 22 24 28
0.1758	725.1	1 2 4 7 9 10 12 15 16 17 18 19 20 21 22 24 28
0.1792	726.3	1 2 7 9 10 12 13 15 16 17 18 19 20 21 22 24 28
0.1800	747.3	1 2 7 9 10 13 15 16 17 18 19 20 21 22 24 25 28
0.1802	773.6	1 2 4 7 9 10 13 15 16 17 18 19 20 22 24 25 28
0.1835	775.5	1 2 4 7 9 10 13 15 16 17 18 19 20 21 22 24 28
0.1841	783.9	1 2 4 7 9 10 12 13 16 17 18 19 20 21 22 24 28
0.1850	785.7	1 4 7 9 10 12 13 16 17 18 19 20 21 22 23 24 28
0.1859	790.7	1 2 4 9 10 11 13 15 16 17 18 19 20 21 22 24 28
0.1882	791.2	1 4 7 9 10 11 13 15 16 17 18 19 20 21 22 24 28
0.1892	806.5	1 7 9 10 12 13 15 16 17 18 19 20 21 22 24 27 28
0.1896	808.4	1 4 7 9 11 12 13 15 16 17 18 19 20 21 22 24 28
0.1900	827.5	1 7 9 10 13 15 16 17 18 19 20 21 22 24 25 27 28
0.1905	829.4	1 4 7 9 11 13 15 16 17 18 19 20 21 22 24 25 28
0.1993	850.5	1 2 4 9 10 12 13 15 16 17 18 19 20 21 22 24 28
0.2017	851.0	1 4 7 9 10 12 13 15 16 17 18 19 20 21 22 24 28

Tabla 6.6. Conjunto de soluciones Pareto Óptimas.

R_s	CT	Variables medidas
0.2026	872.0	1 4 7 9 10 13 15 16 17 18 19 20 21 22 24 25 28
0.2035	918.6	1 4 6 9 10 11 13 15 16 17 18 19 20 21 22 24 28
0.2056	921.8	1 2 4 9 10 12 13 15 17 18 19 20 21 22 24 25 28
0.2081	922.3	1 4 7 9 10 12 13 15 17 18 19 20 21 22 24 25 28
0.2162	978.2	1 3 4 9 10 12 13 15 16 17 18 19 20 21 22 24 28
0.2181	978.4	1 4 6 9 10 12 13 15 16 17 18 19 20 21 22 24 28
0.2191	999.4	1 4 6 9 10 13 15 16 17 18 19 20 21 22 24 25 28
0.2231	1049.5	1 3 4 9 10 12 13 15 17 18 19 20 21 22 24 25 28
0.2251	1049.7	1 4 6 9 10 12 13 15 17 18 19 20 21 22 24 25 28
0.2275	1106.9	3 4 6 9 10 12 13 15 16 17 18 19 20 21 22 24 28
0.2285	1127.9	3 4 6 9 10 13 15 16 17 18 19 20 21 22 24 25 28
0.2348	1178.2	3 4 6 9 10 12 13 15 17 18 19 20 21 22 24 25 28

Continuación Tabla 6.6

La Figura 6.1 muestra la evolución del AE con mil generaciones, en ella aparecen la población inicial completa y, para las generaciones subsiguientes sólo el primer frente obtenido. A partir de la generación 50 se observa ya la convergencia de las soluciones hacia la superficie Pareto óptima; la cual se encuentra representada por el conjunto correspondiente a la generación número 1000.

En la Figura 6.2 se muestra el comportamiento del algoritmo entre las generaciones 50 y 1000. Puede apreciarse que a partir de la generación número 300 no se observan cambios sustanciales en el frente Pareto obtenido. La generación número 1000 aparece totalmente cubierta por los puntos pertenecientes a la número 300; a excepción de tres soluciones de alto costo y confiabilidad. Los puntos extremos del conjunto Pareto óptimo corresponden a los óptimos para los casos de función objetivo simple con costo y confiabilidad como criterios de desempeño mostrados en la Tabla 6.4.

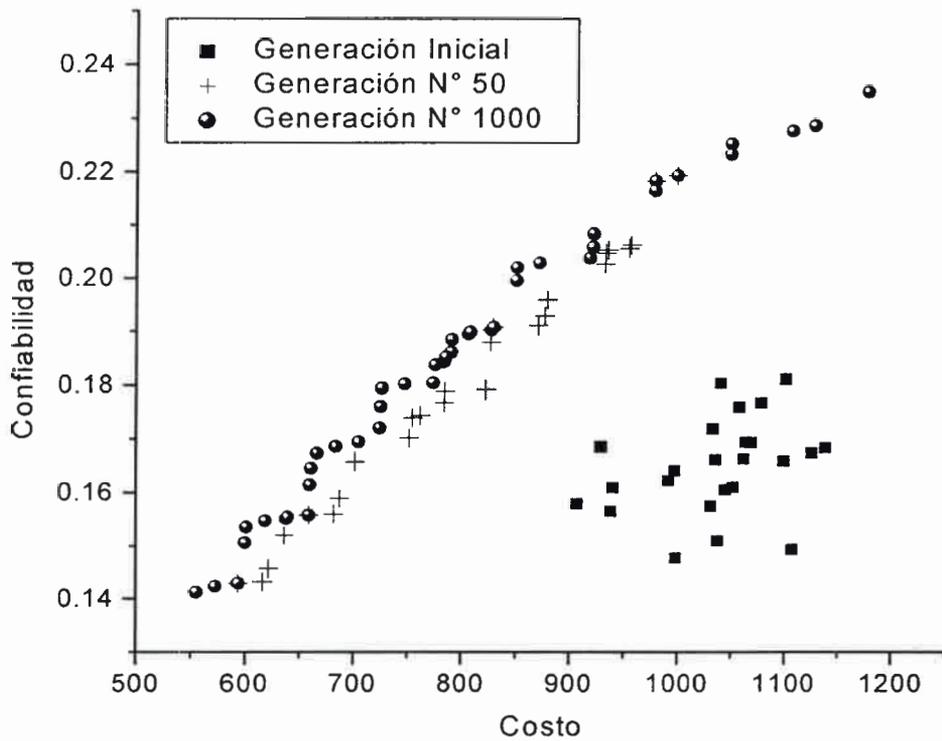


Figura 6.2. Evolución del AE con 1000 generaciones

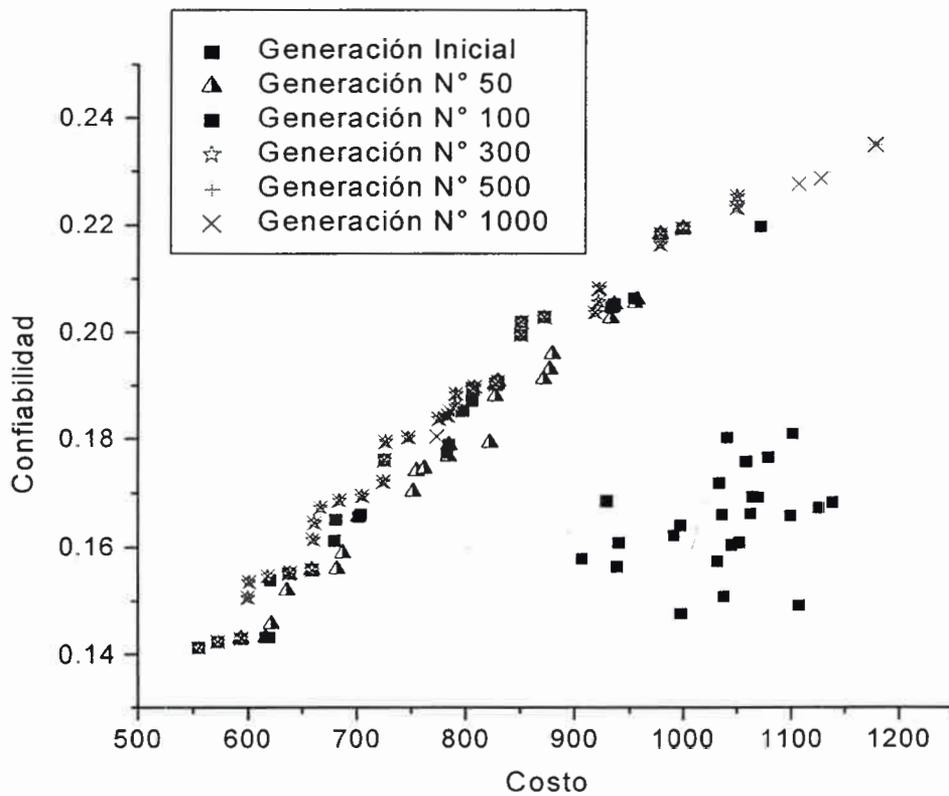


Figura 6.3. Evolución del AE

6.5 Caso 3

En este apartado se analizan los resultados obtenidos para el diseño de instrumentación en su versión más general utilizando un AE de población estructurada.

Se proponen 4 diseños diferentes, correspondientes a distintos conjuntos de variables claves con distintos requerimientos en su estimabilidad y precisión, manteniendo el costo como criterio a optimizar. En la Tabla 6.7 se listan los parámetros del AE utilizado.

Parámetro	Valor
Tamaño de la población	100
Probabilidad $MI = -1$	0.4
Probabilidad $MI=1$	0.3
Método de Selección	Selección local por ranking
Presión selectiva	1.3
Tamaño de la vecindad	7
Probabilidad de mutación	0.025
Probabilidad de cruzamiento	0.7

Tabla 6.7. Parámetros del AE

En la Tabla 6.8 se muestran los datos para el primer diseño analizado, junto con los resultados de la optimización.

Variables claves	σ_i^*	σ_i	Variables Medidas	CT
1	-----	$\sigma_1=0.0215$	1 2 6 7 9 10 13 20 26 28	533.56
2	$\sigma_2^*=0.025$	$\sigma_2=0.025$		
6	$\sigma_6^*=1.7851$	$\sigma_6=1.6552$		

Tabla 6.8. Datos y Resultados del Diseño 1

En la Figura 6.4 se muestra el comportamiento del AE para 100 experimentos del mismo, con 100 generaciones cada uno. El mejor valor encontrado, correspondiente a un valor del costo total $CT= 533.56$, fue alcanzado el 67 % de las veces, con *fitness* promedio para las 100 corridas de 555.7468 y una dispersión de 49.17; lo que indica que en las restantes ejecuciones se obtuvieron buenas soluciones.

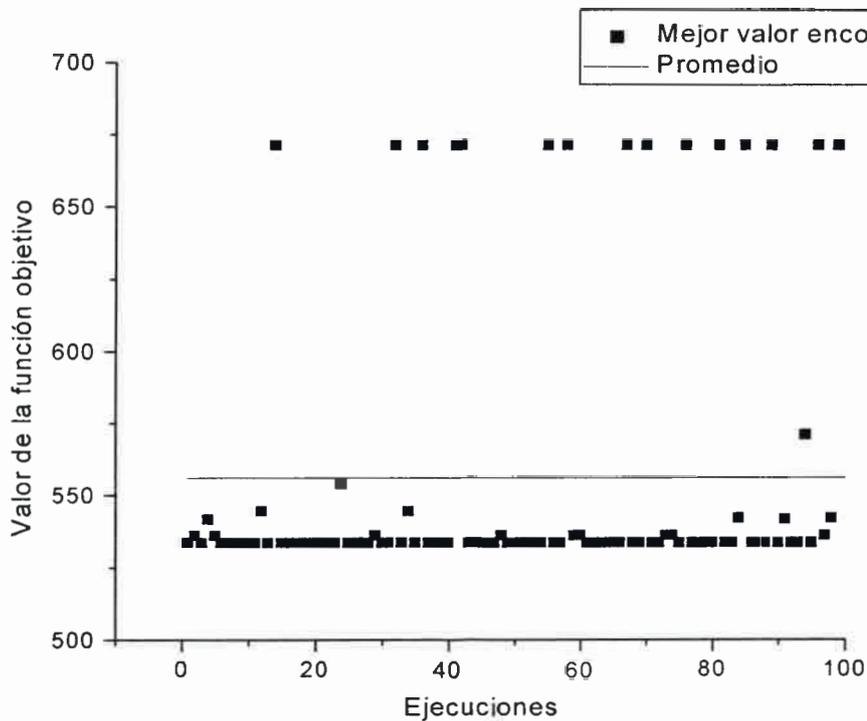


Figura 6.4. Comportamiento del AE para 100 experimentos

En la Figura 6.5 se muestra además la evolución del AE para 100 generaciones. En ella puede observarse que aún con una población inicial compuesta por una gran cantidad de individuos penalizados (individuos no factibles desde el punto de vista de la precisión), el algoritmo no sólo converge, sino que obtiene al final de la ejecución un gran número de individuos factibles, muchos de ellos en el valor óptimo obtenido. Además se advierte la influencia de la utilización de vecindades en la distribución de soluciones subóptimas en regiones específicas de la población final.

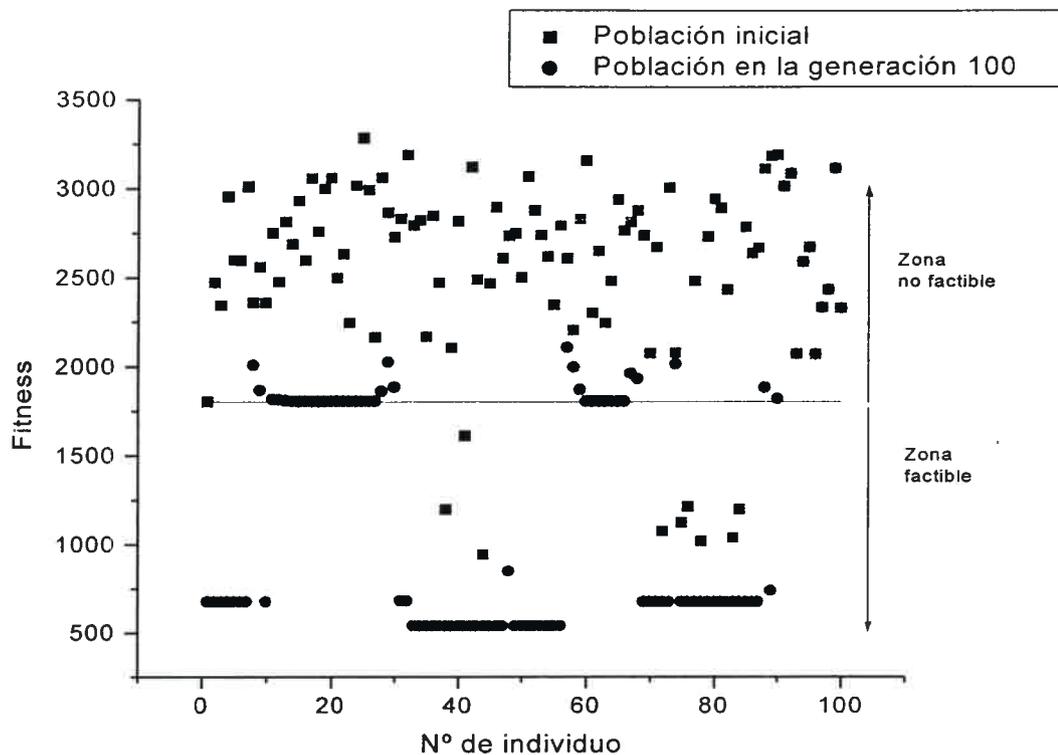


Figura 6.5. Evolución del AE para 100 generaciones

Con el objetivo de comparar el desempeño del algoritmo con selección local versus un algoritmo con selección panmítica, se realizaron para este diseño experiencias similares. El AE panmítico que se implementó mantiene esencialmente las mismas condiciones que el utilizado con población descentralizada, esto es, iguales parámetros, el mismo tipo de operadores de mutación y cruzamiento e hibridización.

Los resultados obtenidos para 100 experimentos del algoritmo panmítico, con 100 generaciones cada uno, se muestran en la Figura 6.6. El mejor valor encontrado, correspondiente a un valor del costo total $CT= 533.56$, fue alcanzado el 44 % de las veces, mientras que la solución con un costo total $CT= 671$ se obtuvo en el 54% de las ejecuciones. El valor con *fitness* promedio para las 100 corridas fue de 607.9496 con una dispersión de 68.67. Si se comparan estos valores con los obtenidos con el modelo de selección local, puede apreciarse el mejor desempeño de este respecto del modelo panmítico. Lo mismo se evidencia comparando la Figura 6.5 con la Figura 6.7.

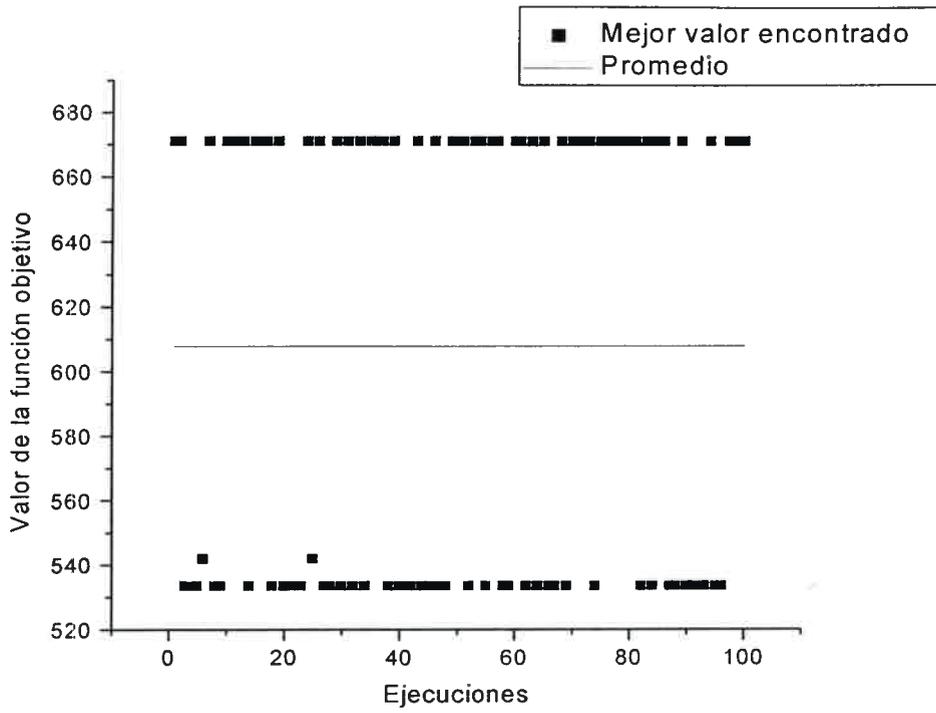


Figura 6.6. Comportamiento del AE panmítico para 100 ejecuciones

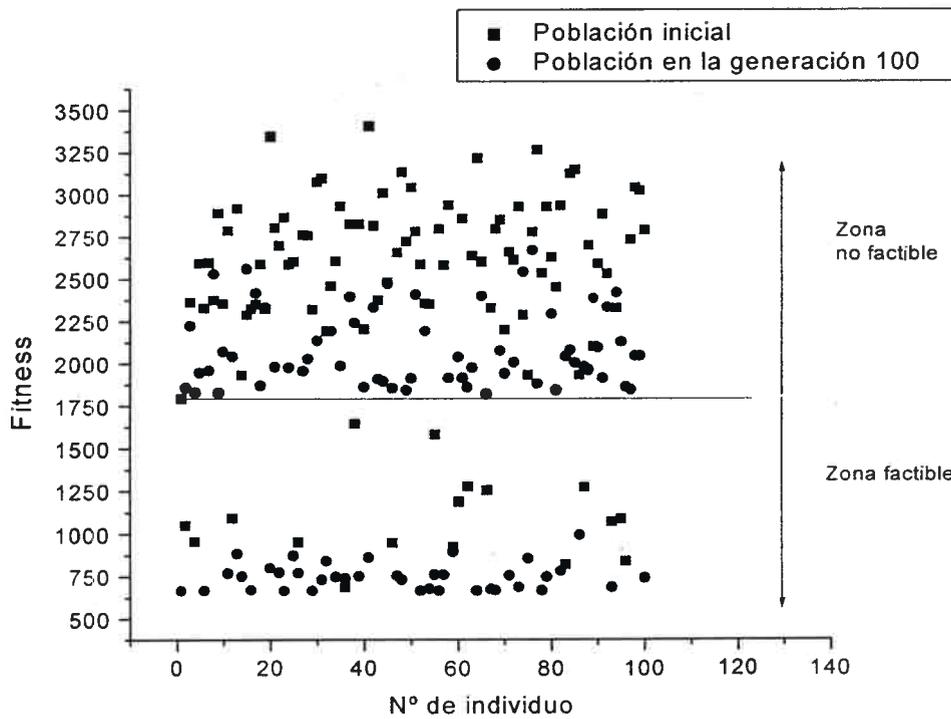


Figura 6.7. Evolución del AE panmítico para 100 generaciones

El segundo diseño analizado también requiere la observabilidad de un conjunto de tres variables claves, solo que correspondientes a corrientes muy alejadas físicamente entre si. Las restricciones de precisión se imponen sobre dos de ellas. En la Tabla 6.9 se muestran los datos y los resultados de la optimización.

Variables claves	σ_i^*	σ_i	Variables Medidas	CT
2	-----	$\sigma_2=0.025$	1 2 5-10 13 19 20 23 26-28	894.86
10	$\sigma_{10}^*=1.0482$	$\sigma_{10}=0.8861$		
28	$\sigma_{28}^*=1.4446$	$\sigma_{28}=1.435$		

Tabla 6.9. Datos y resultados del Diseño 2

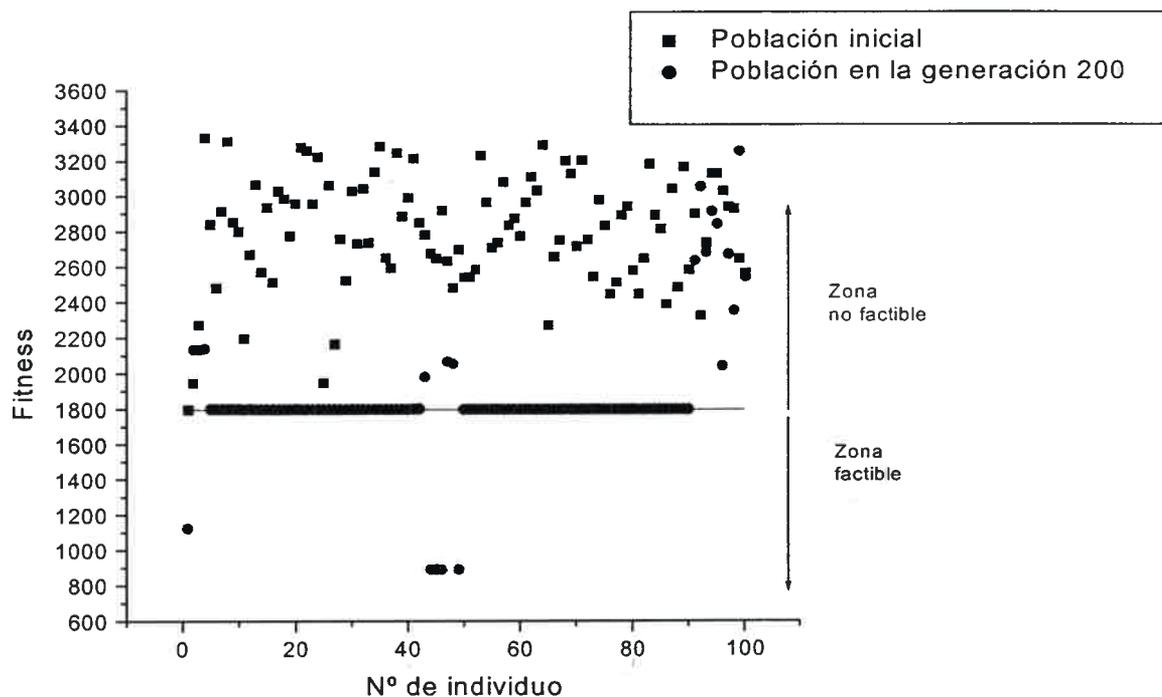


Figura 6.8. Evolución del AE

En la Figura 6.8 puede apreciarse la población inicial y al cabo de 200 generaciones para este caso. En contraste con el caso anterior, el número de individuos no factibles constituyen casi todo el espacio de búsqueda al inicio del algoritmo; sólo

una solución correspondiente a la medición de todas las variables del proceso, no está penalizada. A pesar de que esto constituye una situación extrema, el algoritmo muestra suficiente robustez para converger hacia zonas de buen *fitness*.

La repetitividad de los resultados obtenidos se muestra en la Figura 6.9, con 200 generaciones en cada experimento. La distribución de las soluciones encontradas tiene un valor medio de 943.158, y un valor mínimo de 894.86 que se repite el 56 % de las veces. La dispersión alrededor del valor medio es de 89.71.

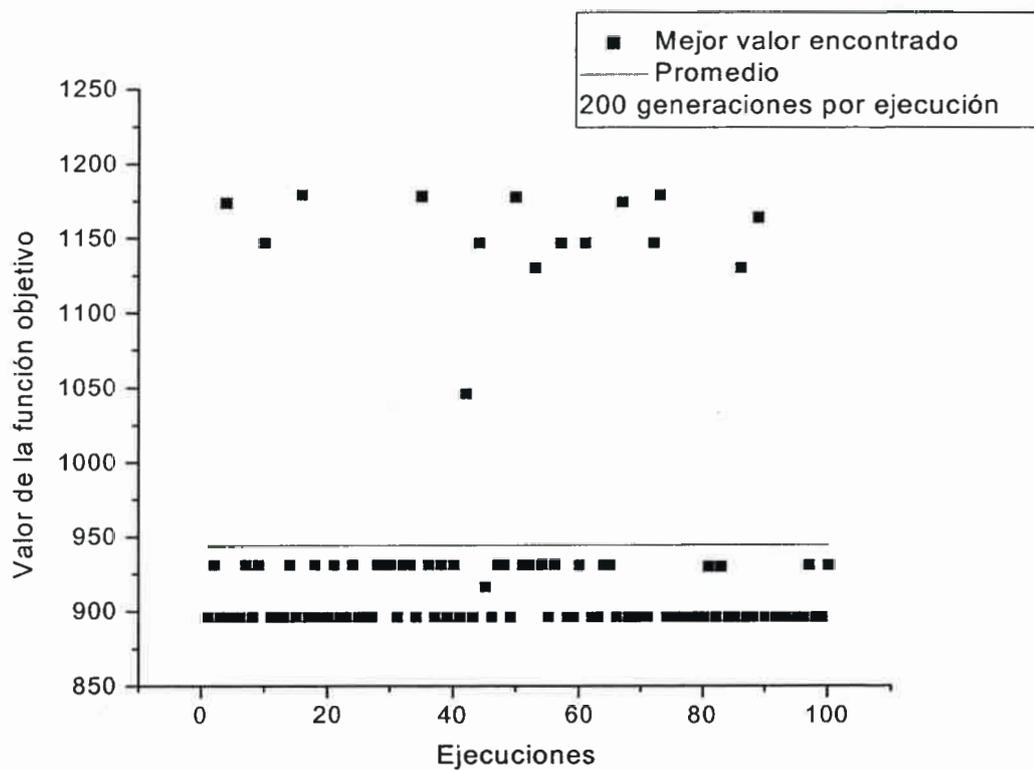


Figura 6.9. Distribución de los resultados obtenidos

El tercer caso corresponde a una instancia del problema donde se requiere un conjunto mayor de variables claves sujetas a restricciones. En la Tabla 6.10 se resumen los datos y resultados obtenidos

Variables claves	σ_i^*	σ_i	Variables Medidas	CT
4	$\sigma_4^*=2.1990$	$\sigma_4=2.1857$	1 4 6 7 9 10 11 14 16-24	752.26
8	$\sigma_8^*=3.281$	$\sigma_8=2.5644$		
17	-----	$\sigma_{17}=0.8048$		
21	$\sigma_{21}^*=1.754$	$\sigma_{21}=1.5018$		
23	-----	$\sigma_{23}=0.0648$		
25	$\sigma_{25}^*=1.7090$	$\sigma_{25}=1.4864$		

Tabla 6.10. Datos y Resultados del Diseño 3

En la Figura 6.10 se muestra la evolución del AE. Exhibe una mayor relación inicial entre el espacio de soluciones factibles y penalizadas, lo que favorece una buena convergencia hacia el mejor valor encontrado.

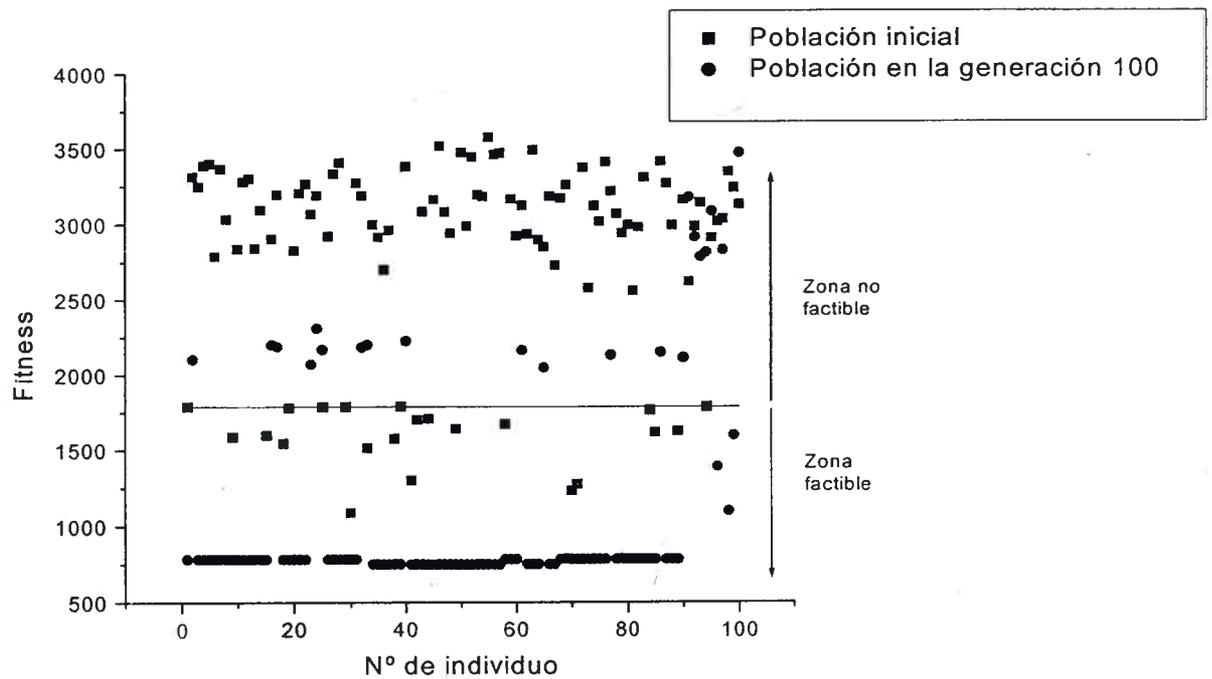


Figura 6.10. Evolución del AE

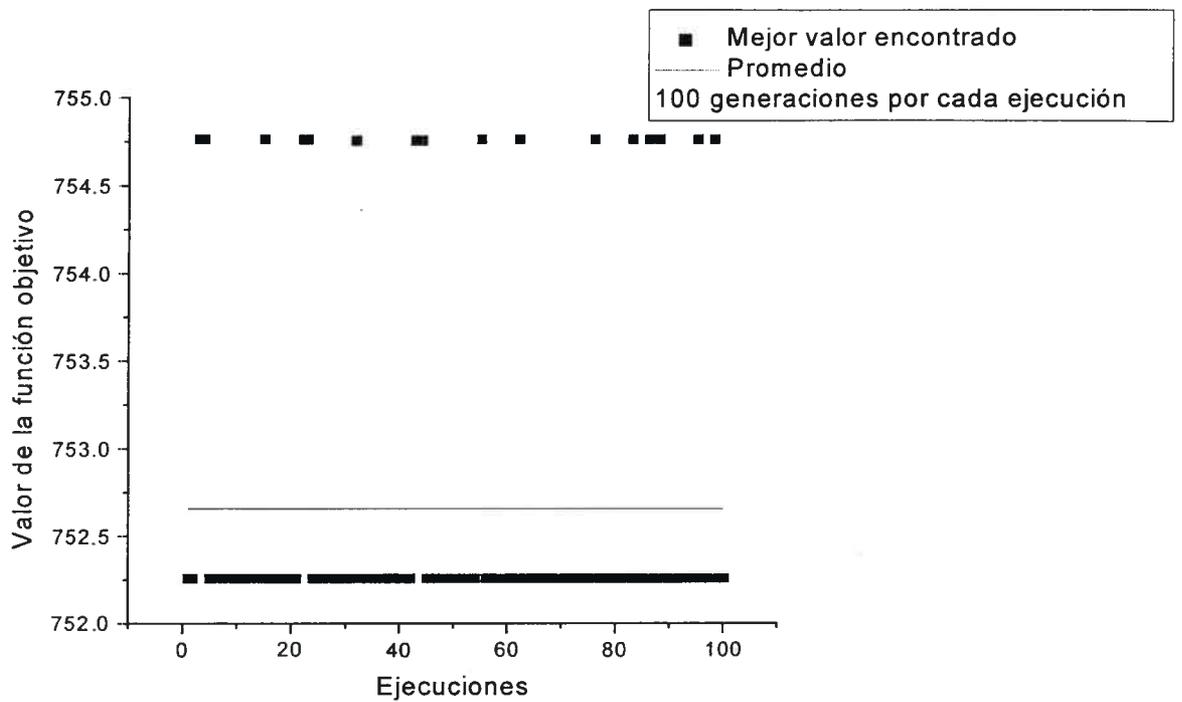


Figura 6.11. Distribución de los resultados obtenidos

Lo anteriormente mencionado influye también en el desempeño del algoritmo, mostrado en la Figura 6.11. El mejor valor encontrado, correspondiente a un valor de 752.26 de la función objetivo, fue alcanzado el 84 % de las veces, con *fitness* promedio para las 100 corridas de 752.66. Esto implica una dispersión alrededor del promedio de 0.9211.

La última instancia del problema resuelta se presenta en la Tabla 6.11. En las Figuras 6.12 y 6.13 se muestran la evolución del AE y su comportamiento al cabo de 100 experimentos; observándose una situación similar al diseño anterior en cuanto a la constitución de la población inicial y su posterior evolución. Respecto a la distribución de las soluciones encontradas, el mejor valor se repite el 100 % de las ejecuciones.

Variables claves	σ_i^*	σ_i	Variables Medidas	CT
4	$\sigma_4^*=2.1990$	$\sigma_4=2.0368$	1 2 4 5-7 9-11 13 15-24 26-28	1178.06
5	$\sigma_5^*=1.0654$	$\sigma_5=0.8878$		
7	-----	$\sigma_7=0.0580$		
8	$\sigma_8^*=3.2810$	$\sigma_8=1.4967$		
12	$\sigma_{12}^*=1.3454$	$\sigma_{12}=0.9588$		
16	-----	$\sigma_{16}=0.5848$		
18	-----	$\sigma_{18}=0.3965$		
20	-----	$\sigma_{20}=0.2614$		
27	$\sigma_{27}^*=1.4154$	$\sigma_{27}=1.2002$		
28	$\sigma_{28}^*=1.4446$	$\sigma_{28}=1.4437$		

Tabla 6.11. Datos y Resultados del Diseño 4

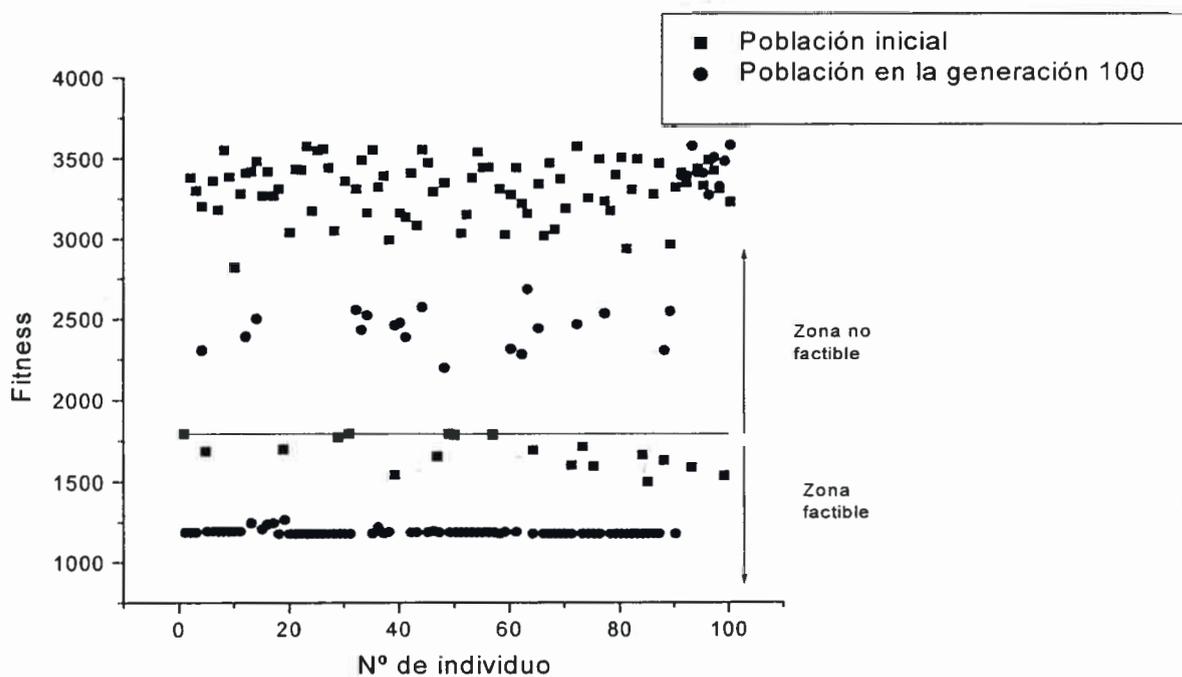


Figura 6.12. Evolución del AE

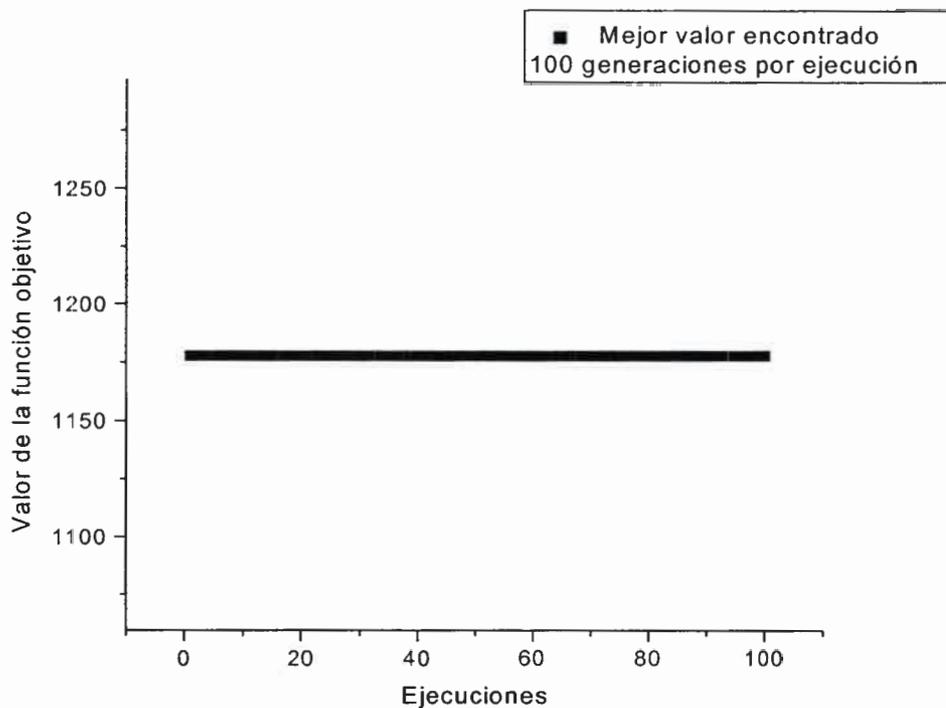


Figura 6.13. Distribución de los resultados obtenidos

El AE implementado ha demostrado poseer robustez: partiendo de una población inicial con un gran porcentaje de individuos no factibles se ha logrado obtener el valor óptimo en tiempo razonable. El AE encuentra la mejor solución al cabo de alrededor de 140 segundos sobre una computadora Pentium III, 1GHz.

La relación entre cantidad de individuos factibles y no factibles tiene influencia en el comportamiento del AE aunque no en la calidad de la solución obtenida sino en el número de generaciones necesario para hallarla. El Caso 2 es un ejemplo de lo antedicho: un único individuo factible sembrado en la población inicial fue suficiente para asegurar la convergencia. Sin embargo fue necesario fijar el número de iteraciones en el doble que en los otros casos (200 iteraciones).

En cuanto a la calidad de las soluciones, éstas son satisfactorias por cuanto se obtuvo un buen porcentaje de repetitividad del mejor valor encontrado y una baja dispersión alrededor de dicho valor.

Gracias al modelo de vecindades implementado en la selección, el algoritmo

posee capacidad de inspeccionar el espacio de búsqueda con un buen balance exploración versus explotación. Esto puede apreciarse en el hecho que se observan varias copias del óptimo en la última población junto con agrupamientos de soluciones subóptimas en algunas regiones de la población.

La influencia del modelo de población estructurada también pudo apreciarse ejecutando el mismo AE con un modelo panmítico. En este caso el desempeño del algoritmo desde el punto de vista de la cantidad de veces que se obtuvo el óptimo decayó sensiblemente dado que el AE quedaba atrapado en subóptimos con muy baja diversidad.

CAPÍTULO VII

CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS

En esta tesis se han desarrollado e implementado metodologías de resolución para el Diseño Óptimo de Instrumentación en plantas de proceso, representadas por sistemas lineales; adaptables a diferentes formulaciones de diseño.

Los procedimientos de cálculo elegidos fueron meta-heurísticas basadas en AE, los cuales han demostrado ser una herramienta poderosa en los casos en que otros métodos necesitan tiempos prohibitivos para obtener una solución.

Se analizaron los casos de Diseño con Número Mínimo de Sensores, y de Red de Sensores General. Cualquiera sea la formulación escogida, el problema resultante implica encontrar una topología óptima de la red de instrumentos, entre un conjunto finito de posibles combinaciones de mediciones, ésto es resolver un problema de optimización combinatorial. Normalmente tales problemas son fáciles de describir pero dificultosos de resolver, clasificándose varios de ellos como NP-completos.

Para el caso de Diseño de Redes con Número Mínimo de Sensores se examinaron diferentes formulaciones del problema de optimización planteado con una variedad de criterios de desempeño para simple objetivo. La estrategia de resolución empleada consistió en el diseño de un AE con operadores genéticos *ad-hoc* basados en conceptos del álgebra lineal, lo que permitió acotar el espacio de búsqueda del algoritmo sólo a la región factible. También se analizó en este punto el caso multiobjetivo; modificándose el método propuesto, en la etapa de asignación de *fitness* y selección con el objetivo de capturar soluciones Pareto-óptimas. El desempeño del algoritmo fue corroborado con un problema test correspondiente a una planta de pequeñas dimensiones y luego aplicado al diseño de instrumentación en un problema industrial de un sistema de vapor.

El Diseño de Redes de Sensores General contempló un escenario más realista: las restricciones de observabilidad se imponen sólo a un conjunto de las variables de proceso y se incorporan restricciones adicionales de exactitud sobre un subconjunto de estas.

Las características del AE desarrollado fueron las siguientes:

- Población inicial sembrada en forma tal que se garantice que todos los individuos presentes verifiquen la restricción de observabilidad y que al menos uno cumpla con ambas restricciones
- Tratamiento de restricciones utilizando el método de penalización
- Población estructurada con modelo de vecindades lineales
- Selección local por ranking
- Hibridización

El desempeño del algoritmo se analizó para instancias de diferentes tamaños: para el diseño de instrumentación de una planta con 8 corrientes y 5 equipos, problema test, y para el diseño de una planta con 28 corrientes y 11 equipos. El primer caso permitió corroborar el valor óptimo obtenido utilizando como técnica de búsqueda un algoritmo de *branch and bound*.

En el segundo caso se evaluó el comportamiento del AE para diferentes conjuntos de variables requeridas para observabilidad y precisión, manteniendo el costo como criterio a optimizar. El análisis de cada uno de estos casos sirvió para mostrar la robustez y capacidad exploratoria del algoritmo, así como la convergencia hacia soluciones de alta calidad.

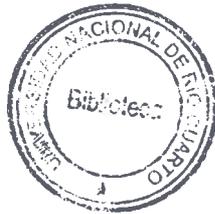
Las principales ventajas observadas en la utilización de AE para la resolución de diseños de redes de instrumentos son las siguientes:

- 1- No requieren de una formulación matemática especial de la función objetivo, más aún, ellos están diseñados para utilizar las funciones objetivo como cajas negras, por lo tanto pueden adaptarse a la resolución de diferentes diseños de instrumentación, incluyendo diseños con criterios múltiples de desempeño.
- 2- En problemas combinatorios complejos, donde la formulación particular no admite la obtención de soluciones óptimas mediante un algoritmo de tiempo polinomial, los AE pueden proveer buenas soluciones en tiempos de ejecución razonables.
- 3- A diferencia de otras metaheurísticas utilizadas para la resolución de problemas combinatorios, ellos exploran en forma simultánea diferentes regiones del espacio de búsqueda. Esto significa que en cualquier estadio de la evolución del algoritmo se tiene un conjunto de candidatos o potenciales soluciones, en contraste con los métodos secuenciales o constructivos que consideran una única solución o una parte de ella respectivamente.
- 4- Resulta relativamente fácil ejecutarlos en las modernas arquitecturas masivas en paralelo. Esta implementación puede ser deseable en los casos en que estén involucrados diseños con un gran número de variables de proceso y por lo tanto la demanda de recursos computacionales se incrementa considerablemente.

Finalmente a continuación se detallan futuras tareas de investigación:

- Para el diseño de redes generales en sistemas lineales, investigar representaciones alternativas de las soluciones y diseño de operadores *ad-hoc* para el manejo de la restricción de observabilidad del conjunto de variables claves. Así mismo desarrollar y comparar funciones de penalización alternativas a la propuesta en relación a las restricciones de exactitud.
- Para este mismo caso, investigar diferentes modelos de AE desde el punto de vista de la estructura de la población. Concretamente experimentar con otras topologías para el modelo de vecindades y con el modelo de islas.
- Implementar los modelos anteriores sobre arquitecturas en paralelo.

- Abordar el problema de optimización multiobjetivo para el caso correspondiente al Capítulo 5.
- Comparar el desempeño del AE frente a otras técnicas heurísticas, tales como búsqueda tabú.
- Extender las estrategias desarrolladas al diseño de sistemas de monitoreo para procesos representados por sistemas de ecuaciones lineales y bilineales.



REFERENCIAS BIBLIOGRÁFICAS

- Alba, E. and M. Tomassini, "Parallelism and Evolutionary Algorithms," *IEEE Transactions of Evolutionary Computation*, **6**, 443-462 (2002).
- Ali, Y. and S. Narasimhan, "Sensor Network Design for Maximizing Reliability of Linear Processes," *AIChE J.*, **39**, 820-828 (1993).
- Ali, Y. and S. Narasimhan, "Redundant Sensor Network Design for Linear Processes", *AIChE J.*, **41**, 2237-2249 (1995).
- Ali, Y. and S. Narasimhan, "Sensor Network Design for Maximizing Reliability of Bilinear Processes," *AIChE J.*, **42**, 2563-2575 (1996).
- Bäck, T., *Evolutionary Algorithms in Theory and Practice*, Oxford University Press, UK (1996).
- Bäck, T., U. Hammel and P. Schwefel, "Evolution Computation: Comments on the History and Current State," *IEEE Transactions of Evolutionary Computation*, **1**, 3-17 (1997).
- Bagajewicz, M., "Design and Retrofit of Sensor Networks in Process Plants," *AIChE J.*, **43**, 2300-2306 (1997).
- Bagajewicz, M. and M. Sánchez, "Cost Optimal Design and Upgrade of Non-Redundant and Redundant Linear Sensor Networks," *AIChE J.*, **45**, 1927-1938 (1999).
- Bagajewicz, M., *Design and Upgrade of Process Plant Instrumentation*, Technomic, Pennsylvania (2000).
- Bagajewicz, M. and E. Cabrera, "A New MILP Formulation for Instrumentation Network Design and Upgrade," *Proc. of IFAC Workshop on On-Line Fault Detection and Supervision in the Chemical Process Industries*, Seoul, Korea, 303-308 (2001).
- Bagajewicz, M., "A Review of Techniques for Instrumentation Design and Upgrade in Process Plants," *The Canadian Journal of Chemical Engineering*, **80**, 3-16 (2002).

- Baker, J., "Adaptive Selection Methods for Genetic Algorithms," *Proc. of the 1st International Conference on Genetic Algorithms and Their Applications*, Pittsburgh, USA, 101-111 (1985).
- Bansal, P., Y. Ali and S. Narasimhan, "Sensor Network Design for Linear Processes," *Proc. of IFAC Workshop on Integration of Process Design and Control*, Maryland, USA, 195-200 (1994).
- Bhushan, M., R. Rengaswamy, "Comprehensive Design of a Sensor Network for Chemical Plants based on Various Diagnosability and Reliability Criteria 1 Framework," *Industrial and Engineering Chemistry Research*, **41**, 1826-1839 (2002).
- Bickle, T. and L. Thiele, "A Comparison of Selection Schemes used in Evolutionary Algorithms," *Evolutionary Computation*, **4**, 361-394 (1996).
- Brooke, A.D., D. Kendrick and A. Meeraus, "GAMS: A User's Guide," *Scientific Press*, San Francisco (1992).
- Carnero, M.; J. Hernández, M. Sánchez and A. Bandoni, "A Strategy for Sensor Network Design Based on an Evolutionary Approach," *Proc. of AIChE Annual Meeting*, Dallas, USA, (1999).
- Carnero, M.; J. Hernández, M. Sánchez and A. Bandoni, "Multiobjective Evolutionary Optimization in Sensor Network Design," *Proc. of ENPROMER'01 – 3rd Congress on Process Engineering for the MERCOSUR*, Santa Fé, Argentina, 325-330 (2001a).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "An Evolutionary Approach for the Design of Non-Redundant Sensor Networks," *Industrial and Engineering Chemistry Research*, **40**, 5578-5584 (2001b).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "Diseño de Redes Redundantes de Sensores Utilizando Algoritmos Evolutivos," *Proc. del Cuarto Simposio Argentino de Inteligencia Artificial*, Santa Fe, Argentina, 242-254 (2002).

- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "Availability of Key Process Variable Estimates: An Evolutionary Approach," Enviado al Congreso *Escape 14*, Lisboa, Portugal (2004).
- Chen, W., *Applied Graph Theory*, North Holland Publisher, Amsterdam (1971).
- Chmielewski, D., T. Palmer and V. Manousiouthakis, "On the Theory of Optimal Sensor Placement," *AIChE J.*, **48**, 1001–1012 (2002).
- Collins, J., *Studies in Artificial Evolution*, PhD Thesis, University of California, USA (1992).
- Costa, L. and P. Oliveira, "Evolutionary Algorithms Approach to the Solution of Mixed Integer Non-Linear Programming Problems," *Computers and Chemical Engineering*, **25**, 257-266 (2001).
- De Jong, K., *An Analysis of the Behavior of a Cass of Genetic Adaptive Systems*, PhD Thesis, University of Michigan, USA (1975).
- Deb, K., "An Efficient Constraint Handling Method for Genetic Algorithms," *Comp. Meth. Appl. Mech. Eng.*, **186**, 311-338 (2000).
- Deb, K., *Multi-Objective Optimization Using Evolutionary Algorithms*, Wiley, Chichester (2001).
- Deo, N., *Graph Theory with Applications to Engineering and Computer Science*, Prentice Hall, Englewood Cliffs, N.J. (1974).
- Eshelman, L. J., R. A. Caruana and J. D. Schaffer, "Biases in the Crossover Landscape," *Proc. of the Third International Conference on Genetic Algorithms*, Los Altos, CA, USA, Morgan Kaufmann Pulbishers, 10-19 (1989).
- Esquivel, S., H. Leiva and R. Gallard, "Multiple Crossovers Between Multiple Parents To Improve Search In Evolutionary Algorithms," *Proc. of the 1999 Congress on Evolutionary Computation (IEEE)*, Washington DC, USA, 1589-1594 (1999).
- Even, S., *Graph Algorithm*, Computer Science Press, Maryland (1979).

- Floudas, C; *Nonlinear and Mixed-Integer Optimization – Fundamentals and Applications*, Oxford University Press , New York , 1995.
- Fonseca, C. M. and P. J. Fleming, “Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion, and Generalization,” *Proc. of the Fifth International Conference on Genetic Algorithms*, Illinois, USA, 416-423 (1993).
- Garey, M. and D. Johnson, *Computers and Intractability. A Guide to the theory of NP-Completeness*, W.H. Freeman and Company, New York (1999).
- Gen, M., *Genetic Algorithms and Engineering Design*, Wiley & Sons, Inc., New York (1996).
- Glover, F., “Surrogate Constraints Duality in Mathematical Programming”, *Operations Research*, **23**, 434-451 (1975).
- Goldberg, D.E., *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, (1989).
- Heraud, N. and H. Mazzour, “Sensor Network Design for Process Described by Linear – Bilinear Equations,” *Proc. Instn. Mech. Engrs*, **213**, 321-329 (1999).
- Holland, J., *Adaptation in Natural and Artificial Systems*, University of Michigan, USA (1975).
- Kretsovalis, A. and R. S. H. Mah, “Effect of Redundancy on the Estimation Accuracy in Process Data Reconciliation,” *Chem. Engng. Sci.*, **42**, 2115–2121 (1987).
- Luong, M., D. Maquin, C. Huynh and J. Ragot, “Observability, Redundancy, Reliability and Integrated Design of Measurement Systems,” *Proc. of 2nd. IFAC Symposium on Intelligent Components and Instrument Control Applications*, Budapest, Hungria (1994).
- Luyben, M.L. and C.A. Floudas, “Analyzing the Interaction of design and control-1. A multiobjective framework and application to binary distillation synthesis,” *Computers and Chemical Engineering*, **18**, 933-969 (1994a).

- Luyben, M.L. and C.A. Floudas, "Analyzing the interaction of design and control-2. reactor-separator-recycle system," *Computers and Chemical Engineering*, **18**, 971-994 (1994b).
- Madron, F., *Process Plant Performance. Measurement and Data Processing for Optimisation and Retrofits*, Ellis Horwood Ltd., Chichester (1992).
- Madron, F. and V. Veverka, "Optimal Selection of Measuring Points in Complex Plants by Linear Models," *AIChE J.*, **38**, 227-236 (1992).
- Mah, R.S.H., G. Stanley and D. Dowing, "Reconciliation and Rectification of Process Flow and Inventory Data," *Ind. Engng. Chem. Process Des. Dev.*, **15**, 175-183 (1976).
- Mah, R.S.H., *Chemical Process Structures and Information Flows*, Butterworths, Boston (1990).
- Maquin, D., M. Darouach, J. Fayolle and J. Ragot, "Localization of Sensors in Large Scale Industrial Systems," *Applied Modeling and Simulation of Technological Systems*, Elsevier Science Publishers B. V., Holanda (1987).
- Maquin, D., M. Luong, J. Ragot, "Observability Analysis and Sensor Placement," *Proc. of SAFE PROCESS' 94, IFAC/IMACS Symposium on Fault Detection, Supervision and Safety for Technical Process*, Espoo, Finland (1994).
- Meyer, M., J.M. Le Lann, B. Koehret and M. Enjalbert, "Optimal Location of Sensor Location on a Complex Plant Using a Graph Oriented Approach," *Computers and Chemical Engineering*, **18 Supp.**, S535-S540 (1994).
- Michalewicz, Z., *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, Berlin Heidelberg, New York (1996).
- Narasimhan, S. and C. Jordache, *Data Reconciliation and Gross Error Detection*, Gulf Publishing Company, Houston (2000).
- Nemhauser, G. and L. Wolsey, *Integer and Combinatorial Optimization*, Wiley Interscience, New York, (1999).

- Ogunaike, B. and K. Steiglitz, *Process Dynamic Modeling and Control*, Oxford University Press, UK (1994).
- Papadimitriou, C., and K. Steiglitz, *Combinatorial Optimization – Algorithms and Complexity*, Prentice Hall, New Jersey (1982).
- Peters, M. S. and K. D. Timmerhaus, *Plant Design and Economics for Chemical Engineers*, Mc. Graw-Hill, New York (1980).
- Ragot, J., D. Maquin and G. Bloch, “Sensor Positioning for Processes Described by Bilinear Equations,” *Revue Diagnostic et Surete de Fonctionnement*, **2**, 115-132 (1992).
- Romagnoli, J. and Sánchez, M., *Data Processing and Reconciliation for Chemical Process Operations*, Academic Press, San Diego (1999).
- Sánchez, M.; *Monitoreo de Procesos Continuos: Análisis de la Instrumentación y Reconciliación de Datos de Planta*, Tesis Doctoral, Universidad Nacional del Sur, Argentina (1996).
- Sánchez, M. and J. Romagnoli, “Use of Orthogonal Transformations in Classification/Data Reconciliation”, *Computers and Chemical Engineering*, **20**, 483-493 (1996).
- Sánchez, M. and M. Bagajewicz, “On the Impact Of Corrective Maintenance in the Design of Sensor Networks”, *Industrial and Engineering Chemistry Research*, **39**, 977-981 (2000).
- Sarma, J. and K. De Jong, “An Analysis of Local Selection Algorithms in a Spatially Structured Evolutionary Algorithm”, *Proc. of the 7th International Conference on Genetic Algorithms*, Lansing, USA (1997).
- Schaffer, J. D., *Some experiments in machine learning using vector evaluated genetic algorithms*, Tesis Doctoral, Vanderbilt University, Nashville, TN (1984).
- Schaffer, J. D., “Multiple objective optimization with vector evaluated genetic algorithms”. *Proc. of the First International Conference on Genetic Algorithms*, Pittsburgh, USA, 93-100 (1985).

- Schütz, M. and H. Schwefel, "Evolutionary Approaches to solve three Challenging Engineering Tasks," *Comp. Meth. Appl. Mech. Eng.*, **186**, 141-170 (2000).
- Seborg, D.E., T.F. Edgar and D.A. Millichamp, *Process Dynamics and Control*, John Wiley, New York (1989).
- Sen, S., S. Narasimhan and K. Deb, "Sensor Network Design of Linear Processes using Genetic Algorithms", *Computers and Chemical Engineering*, **22**, 385-390 (1998).
- Serth, R. and W. Heenan, "Gross Error Detection and Data Reconciliation in Steam-Metering Systems," *AIChE J.*, **32**, 733-741 (1986).
- Spronck, P., *Elegance: Genetic Algorithms in Neural Reinforcement Control*, Master Thesis, Faculty of Technical Mathematics and Informatics, Delft University of Technology, Holanda (1996).
- Srinivas, N. and K. Deb, "Multiobjective Optimization Using Nondominated Sorting In Genetic Algorithms," *Journal of Evolutionary Computation*, **2**, 221-248 (1994).
- Václavek, V., "Studies on System Engineering III Optimal Choice of the Balance Measurements in complicated Chemical Engineering Systems," *Chem. Engng. Sci.*, **24**, 947-955 (1969).
- Vaclavek, V. and M. Loucka, "Selection of Measurements Necessary to Achieve Multicomponent Mass Balances in Chemical Plant," *Chem. Engng. Sci.*, **31**, 1199-1205 (1976).
- Wright, A., "Genetic Algorithm for Real Parameter Optimization," *Proc. of the First Workshop on the Foundations of Genetic Algorithms and Classifier Systems*, San Mateo, USA, 205-218 (1991).

ANEXO: Trabajos publicados y presentaciones a congresos que surgieron del trabajo de esta tesis

- Carnero, M.; J. Hernández, M. Sánchez and A. Bandoni, "A Strategy for Sensor Network Design Based on an Evolutionary Approach," *Proc. of AIChE Annual Meeting*, Dallas, USA, (1999).
- Carnero, M.; J. Hernández, M. Sánchez and A. Bandoni, "Multiobjective Evolutionary Optimization in Sensor Network Design," *Proc. of ENPROMER '01 – 3rd Congress on Process Engineering for the MERCOSUR*, Santa Fé, Argentina, 325-330 (2001a).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "An Evolutionary Approach for the Design of Non-Redundant Sensor Networks," *Industrial and Engineering Chemistry Research*, **40**, 5578-5584 (2001b).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "Diseño de Redes Redundantes de Sensores Utilizando Algoritmos Evolutivos," Proc. del Cuarto Simposio Argentino de Inteligencia Artificial, Santa Fe, Argentina, 242-254 (2002).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "Availability of Key Process Variable Estimates: An Evolutionary Approach," Enviado al Congreso *Escape 14*, Lisboa, Portugal (2004).

U.N.R.C.
Biblioteca Central



59940

59940

