



UNIVERSIDAD DE LOS ANDES
FACULTAD DE INGENIERIA
ESCUELA DE SISTEMAS
DEPARTAMENTO DE INVESTIGACION DE OPERACIONES

**“UN ALGORITMO EVOLUTIVO PARA LA
OPTIMIZACIÓN DEL MÉTODO DE EXPLOTACIÓN
DE PETRÓLEO CON LEVANTAMIENTO ARTIFICIAL
POR GAS”**

POR: ALDEINDA ROSA PÉREZ LUZARDO

PROYECTO PRESENTADO ANTE LA ILUSTRE UNIVERSIDAD DE LOS ANDES COMO REQUISITO FINAL PARA
OPTAR AL TÍTULO DE INGENIERO DE SISTEMAS

TUTOR:
DR. ELIEZER COLINA

ABRIL DE 2009

*El estudio de tus errores no te revelará el
secreto del éxito, pero el estudio de la
abnegación y el esfuerzo sí lo hará.*

Bernard Holdane

Dedicatoria

Yo, Aldeinda Pérez, dedico este triunfo personal a mi Dios por darme la valentía de aceptar este reto y la fuerza necesaria para afrontarlo y lograr una meta más en mi vida.

A la memoria de mi padre Julio Luzardo, que desde su descanso eterno se que comparte este logro conmigo y me envía toda su sabiduría y amor. Te amo papí siempre te llevé en mi corazón.

A mis dos mamás, amigas fieles. Mi tía Siria por tu apoyo incondicional, por tus consejos en los momentos más oportunos, por tu infinita comprensión y por ser siempre mi soporte y mi guía. A mi abuela Aldeinda por haber puesto todas sus energías en formarme y darme las ganas de ser algo bueno en la vida. Gracias a usted soy quien soy hoy día.

A mi mamá Carmen, a mi Tía Adela (tudu), a mi hermano Luis y a mi tía Marge, por ser parte de los momentos más importantes de mi vida, me han enseñado que hay que luchar por lo que se quiere y hay que perseguir los sueños hasta conseguirlos.

A esta familia maravillosa que Dios me regalo...

Agradecimientos

A Dios, por darme la perseverancia y capacidad para lograr este objetivo primordial en mi vida.

A la Universidad de Los Andes, Facultad de Ingeniería, por permitirme ser integrante de esta importante casa de estudios.

Al Profesor Eliezer Colina, por su paciencia y dedicación, por tener siempre el tiempo para asesorarme dentro de su ocupada planificación y por compartir sus avanzados conocimientos conmigo y ser parte de esta gran investigación.

Al Ingeniero César Bravo, por darme la oportunidad de trabajar a su lado en esta importante investigación, por su confianza y por guiarme y apoyarme durante la realización de mi proyecto de grado.

Al ingeniero Jack Márquez por su carisma, apoyo, comprensión y alto nivel gerencial y por haberme permitido conocer a gente maravillosa y de alto nivel profesional en el SCADA y en el DST en general.

Al Sr. José Ávila por darme una valiosa oportunidad de formar parte de todo esto, sino nada hubiese sido posible, muchas gracias.

Al Profesor Ernesto Ponzot, por su fundamental contribución a mi formación académica y apoyo constante en todo momento de mi carrera.

A Miguel Fernández por su apoyo en la realización de este trabajo. Gracias mi Coso.

A mi amigo Rafael Tovar, por su compañerismo y apoyo durante la realización de este proyecto, gracias mi peque saltamontes.

A mis amigos y familiares que me han apoyado en todo momento.

Resumen

El método de explotación de petróleo por levantamiento artificial con gas, consiste en la inyección de gas de alta presión en un punto de la tubería de producción con el propósito de disminuir la densidad de la columna de fluido, facilitando su traslado hacia la superficie. El mayor requerimiento que presenta esta técnica es el suministro de gas de inyección presurizado, que es un recurso limitado y de disponibilidad variable. Esto puede generar situaciones de contingencia que impidan que un conjunto de pozos sean asistidos a la tasa precisa, lo que se traduce en pérdidas en la producción.

La complejidad del sistema de explotación petrolera, las características particulares de cada pozo, la diversidad de planes de producción por zonas geográficas y otras consideraciones técnicas, sugieren que estamos ante un problema de Optimización Multi-objetivo, donde se deben tomar en cuenta todas las variables que intervienen en el lazo de producción. En esta tesis se presenta la aplicación de los Algoritmos Evolutivos en la optimización de la distribución del gas disponible para inyección, que permita obtener la mayor tasa de producción posible. Este trabajo de grado forma parte del Proyecto de Optimización de la Producción basada en Computación Inteligente, que PDVSA desarrolla a través del Distrito Socialista Tecnológico (DST) de Automatización, Informática y Telecomunicaciones (AIT) en el Estado Mérida.

Palabras Clave: Optimización, Optimización Multi-objetivos, Levantamiento Artificial por Gas, Tasa de Inyección de Gas, Algoritmos Evolutivos.

Indice General

1. INTRODUCCIÓN	1
1.1. Antecedentes.	2
1.2. Planteamiento del problema.	3
1.3. Justificación.	4
1.4. Delimitación de la Investigación y alcance.	5
1.5. Objetivos.	6
1.5.1. Objetivo General.	6
1.5.2. Objetivos Específicos.	6
1.6. Metodología.	7
1.7. Resultados Esperados.	8
1.8. Organización del documento.	8
2. MARCO TEÓRICO	9
2.1. MECANISMOS DE RECUPERACIÓN DE PETRÓLEO.	9
2.2. LEVANTAMIENTO ARTIFICIAL POR GAS (LAG).	11
2.2.1. Tipos de Sistemas de Levantamiento Artificial por Gas.	12
2.2.2. Ventajas y Desventajas del Levantamiento Artificial por Gas.	13
2.2.3. Descripción del Lazo de Producción Petrolera con Levantamiento Artificial por Gas.	15
2.3. OPTIMIZACIÓN DE LA ENERGÍA DISPONIBLE.	19
2.4. OPTIMIZACIÓN MULTI-OBJETIVO.	21

2.4.1.	Optimalidad de Pareto.	24
2.4.2.	Dominancia de Pareto.	25
2.4.3.	Frente de Pareto.	26
2.5.	INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL (IA).	29
2.6.	REDES NEURONALES ARTIFICIALES.	30
2.6.1.	La Neurona Biológica.	31
2.6.2.	La Neurona Artificial.	32
2.6.3.	Redes Neuronales Artificiales.	33
2.6.4.	Redes Neuronales Multicapa.	35
2.6.5.	Algoritmo de Retropropagación.	36
2.6.6.	Método de Levenberg - Marquardt.	37
2.7.	INTRODUCCIÓN A LA COMPUTACIÓN EVOLUTIVA (CE).	38
2.8.	ALGORITMOS EVOLUTIVOS (AE).	40
2.8.1.	Componentes de los Algoritmos Evolutivos.	40
2.8.2.	Esquema General de los Algoritmos Evolutivos.	42
2.8.3.	Ventajas y Desventajas.	43
2.9.	ALGORITMOS EVOLUTIVOS MULTI-OBJETIVO (AEMO).	44
3.	MARCO METODOLÓGICO	47
3.1.	MODELADO DE POZOS.	47
3.2.	MODELO DE OPTIMIZACIÓN MULTI-OBJETIVO.	51
3.3.	ALGORITMO EVOLUTIVO MULTI-OBJETIVO.	54
3.3.1.	Representación de los Individuos.	54
3.3.2.	Ordenamiento No Dominado.	55
3.3.3.	Distancia de Agrupamiento (Crowding Distance).	57
3.3.4.	Operador de comparación de agrupamiento (crowded-comparison-operator).	59
3.3.5.	Operadores Evolutivos.	60
3.3.6.	Ciclo del Algoritmo Evolutivo Multi-objetivo propuesto.	61

4. RESULTADOS Y DISCUSIÓN	64
4.1. RESULTADOS DEL MODELADO DE POZOS.	64
4.2. RESULTADOS DE OPTIMIZACIÓN.	98
4.2.1. Jerarquización de los pozos en estudio.	98
4.2.2. Optimización Evolutiva Multiobjetivo.	98
5. CONCLUSIONES Y RECOMENDACIONES	104
5.1. Conclusiones.	104
5.2. Recomendaciones.	105
. Bibliografía	106
A. Resultados Parciales NSGAI	110
B. Código Fuente.	133

Indice de Tablas

3.1. Variables del Sistema Pozo - Yacimiento. Tomado de [Charrouf, 2001] . . .	48
4.1. Resultados de Entrenamiento y Validación de los Modelos Neuronales. . . .	65
4.2. Jeraquización del Campo en estudio según la mínima inyección y la máxi- ma producción de crudo.	99
4.3. Parámetros de entrada al algoritmo evolutivo.	99
4.4. Conjunto de Soluciones Factibles para el pozo 1 (LLB0018).	100
4.5. Soluciones Óptimas Seleccionadas.	101
4.6. Resultados de la Distribución para La Producción Actual.	102
4.7. Jerarquización de los pozos en estudio.	103
A.1. Conjunto de Soluciones Factibles para el pozo 1 (LLB0018).	111
A.2. Conjunto de Soluciones Factibles para el pozo 2 (LLB0021).	112
A.3. Conjunto de Soluciones Factibles para el pozo 3 (LLB0022).	113
A.4. Conjunto de Soluciones Factibles para el pozo 4 (LLB0026).	114
A.5. Conjunto de Soluciones Factibles para el pozo 5 (LLB0042).	115
A.6. Conjunto de Soluciones Factibles para el pozo 6 (LLB0047).	116
A.7. Conjunto de Soluciones Factibles para el pozo 7 (LLB0050).	117
A.8. Conjunto de Soluciones Factibles para el pozo 8 (LLB0051).	118
A.9. Conjunto de Soluciones Factibles para el pozo 9 (LLB0052).	119
A.10. Conjunto de Soluciones Factibles para el pozo 10 (LLB0053).	120
A.11. Conjunto de Soluciones Factibles para el pozo 11 (LLB0059).	121

A.12. Conjunto de Soluciones Factibles para el pozo 12 (LLB0060).	122
A.13. Conjunto de Soluciones Factibles para el pozo 13 (LLB0061).	123
A.14. Conjunto de Soluciones Factibles para el pozo 14 (LLB0062).	124
A.15. Conjunto de Soluciones Factibles para el pozo 15 (LLB0063).	125
A.16. Conjunto de Soluciones Factibles para el pozo 16 (LLB0064).	126
A.17. Conjunto de Soluciones Factibles para el pozo 17 (LLB0065).	127
A.18. Conjunto de Soluciones Factibles para el pozo 18 (LLB0066).	128
A.19. Conjunto de Soluciones Factibles para el pozo 19 (LLB0067).	129
A.20. Conjunto de Soluciones Factibles para el pozo 20 (LLB0069).	130
A.21. Conjunto de Soluciones Factibles para el pozo 21 (LLB0070).	131
A.22. Soluciones Óptimas Seleccionadas.	132

Indice de Figuras

2.1. Levantamiento Artificial por Gas (LAG)	11
2.2. Tipos de LAG.	13
2.3. Estructura de un pozo con LAG. Tomado de [Industria Petrolera, 2008]. . .	15
2.4. Proceso de Producción de Crudo asistido con LAG.	17
2.5. Sistema de Manejo de Gas de Alta Presión.	18
2.6. Curvas de Rendimiento para diferentes tasas de inyección de gas.	20
2.7. Frente de Pareto.	26
2.8. Ilustración del Problema de Optimización Multiobjetivo.	27
2.9. Partes de la Neurona Biológica.	32
2.10. La Neurona Artificial y sus equivalentes biológicos.	33
2.11. Red Neuronal Multicapa.	36
3.1. Modelo de Regresores de Entrada - Salida.	50
3.2. Diagrama de Flujo del Algoritmo Evolutivo Multi-objetivo (NSGA-2) . . .	63
4.1. Tasa de Inyección de Gas $GL(k)$ vs Tasa de Producción $BN(k)$ del pozo 1 (LLB0018)	67
4.2. Modelado Neuronal del Pozo 1 (LLB0018)	67
4.3. Tasa de Inyección de Gas $GL(k)$ vs Tasa de Producción $BN(k)$ del pozo 2 (LLB0021)	68
4.4. Modelado Neuronal del Pozo 2 (LLB0021)	69

4.5. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 3 (LLB0022)	70
4.6. Modelado Neuronal del Pozo 3 (LLB0022)	70
4.7. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 4 (LLB0026)	71
4.8. Modelado Neuronal del Pozo 4 (LLB0026)	72
4.9. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 5 (LLB0042)	73
4.10. Modelado Neuronal del Pozo 5 (LLB0042)	73
4.11. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 6 (LLB0047)	74
4.12. Modelado Neuronal del Pozo 6 (LLB0047)	75
4.13. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 7 (LLB0050)	76
4.14. Modelado Neuronal del Pozo 7 (LLB0050)	76
4.15. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 8 (LLB0051)	77
4.16. Modelado Neuronal del Pozo 8 (LLB0051)	78
4.17. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 9 (LLB0052)	79
4.18. Modelado Neuronal del Pozo 9 (LLB0052)	79
4.19. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 10 (LLB0053)	80
4.20. Modelado Neuronal del Pozo 10 (LLB0053)	81
4.21. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 11 (LLB0059)	82
4.22. Modelado Neuronal del Pozo 11 (LLB0059)	82

4.23. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 12 (LLB0060)	83
4.24. Modelado Neuronal del Pozo 12 (LLB0060)	84
4.25. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 13 (LLB0061)	85
4.26. Modelado Neuronal del Pozo 13 (LLB0061)	85
4.27. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 14 (LLB0062)	86
4.28. Modelado Neuronal del Pozo 14 (LLB0061)	87
4.29. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 15 (LLB0063)	88
4.30. Modelado Neuronal del Pozo 15 (LLB0063)	88
4.31. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 16 (LLB0064)	89
4.32. Modelado Neuronal del Pozo 16 (LLB0064)	90
4.33. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 17 (LLB0065)	91
4.34. Modelado Neuronal del Pozo 17 (LLB0065)	91
4.35. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 18 (LLB0066)	92
4.36. Modelado Neuronal del Pozo 18 (LLB0066)	93
4.37. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 19 (LLB0067)	94
4.38. Modelado Neuronal del Pozo 19 (LLB0067)	94
4.39. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 20 (LLB0069)	95
4.40. Modelado Neuronal del Pozo 20 (LLB0069)	96

4.41. Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 21 (LLB0070)	97
4.42. Modelado Neuronal del Pozo 21 (LLB0070)	97

Capítulo 1

INTRODUCCIÓN

La producción petrolera es la actividad de la industria que se encarga de todas las etapas necesarias para manejar los hidrocarburos (petróleo y gas) desde el yacimiento hasta el pozo, y desde éste hasta la superficie; donde se separan, tratan, almacenan, miden y transportan, para su posterior utilización. Una vez que se han culminado las actividades de perforación y completación, se procede a la explotación del hidrocarburo.

La estrategia de explotación de un yacimiento es de gran importancia ya que es la que establece los niveles de producción obtenidos de un pozo. Para obtener el mayor beneficio de un yacimiento es necesario seleccionar el método de explotación que mejor se adapte a sus características. Inicialmente, es posible que el pozo pueda producir de forma natural; no obstante finalizada esta alternativa, es necesario utilizar métodos de levantamiento artificial que permitan al pozo seguir produciendo eficientemente [Jennings, Dennis R. and et al., 2000].

Uno de los métodos de levantamiento artificial más utilizado en la industria petrolera es el Levantamiento Artificial por Gas (LAG), que utiliza gas comprimido a alta presión como fuente externa de energía. El gas es inyectado en la tubería de producción del pozo para reducir el peso de los fluidos contenidos en ella. De esta manera la energía del

yacimiento será suficiente para transportar los hidrocarburos desde el fondo hasta la superficie [Barberii, 1998].

Los mecanismos de explotación petrolera así como la mayoría de las actividades de la industria, requieren de diversas herramientas de optimización en sus múltiples áreas para garantizar la calidad de sus complejas operaciones.

La optimización del método de levantamiento artificial por gas se encarga de la obtención del máximo beneficio, acercándose al máximo a la realidad que se presenta a diario en el lazo de producción y es objeto de estudio en esta investigación.

1.1. Antecedentes.

Las técnicas de inteligencia artificial aplicadas a los procesos de producción de hidrocarburos han sido objeto de estudio en múltiples oportunidades a través de institutos de educación y compañías pertenecientes al área, logrando avances significativos en tareas como reconocimiento de patrones, modelaje y optimización.

La optimación de la inyección de gas a los pozos es tema de relevante interés para mejorar los sistemas de producción y disminuir el riesgo de impacto asociado a los paros de planta, motivo por el cual desde los inicios de este sistema de producción se han implementado diferentes medidas de contingencia y métodos de optimización. A continuación se mencionan dos de los aportes mas recientes de los cuales se dispone información, aplicados a la industria petrolera venezolana, en el área de la optimización de la producción.

Una de ellas corresponde a la investigación realizada en la Universidad Nacional Experimental del Táchira por los Ingenieros Richard Salas y Vladimir Aldana, quienes utilizaron la Red Neuronal fusión ARTMAP para el reconocimiento de patrones en los procesos de

levantamiento artificial por inyección de gas [Aldana, V. and Salas, R., 2001].

Adicionalmente se puede mencionar, el proyecto realizado para la para la Gerencia de infraestructura de la Unidad de Exploración y Producción LAGOCINCO de PDVSA, unidad ubicada en el Lago de Maracaibo, el cual recibe el nombre de Optimización de la Tasa de Inyección de Gas basada en Inteligencia Artificial, que utiliza la versatilidad de las redes neuronales y los algoritmos genéticos para optimizar la tasa de inyección en pozos asistidos por LAG [Charrouf, 2001].

1.2. Planteamiento del problema.

Mediante la puesta en marcha, en septiembre de 2006, del Distrito Socialista Tecnológico de Mérida, PDVSA fortalece y fomenta un esquema de tecnología libre al servicio del sector energético nacional. Para esto, un numeroso grupo de investigadores de PDVSA junto con profesores y estudiantes de diversas universidades del país, trabajan en proyectos tecnológicos que en su mayoría benefician el sector energético nacional.

PDVSA AIT desarrolla actualmente el proyecto “Aplicaciones de Optimización de Producción basadas en Computación Inteligente” para métodos de recuperación de petróleo y gas, que permitan mejorar el desempeño de los sistemas de producción y ayudar a obtener la máxima producción posible, al aumento del nivel de hidrocarburos producidos y a la disminución de los costos de operación.

El desarrollo de aplicaciones de optimización inteligente tiene un impacto directo en los barriles producidos y la presente investigación surge como una contribución a esa colección de aplicaciones. Es por esto que la gerencia del proyecto ha creído conveniente encontrar una solución a la problemática referente a la optimización de la explotación por levantamiento artificial con gas y contribuir a la mejor distribución de los recursos disponibles

para inyección.

En el problema planteado, resaltan tres aspectos fundamentales:

- Se consideran distintos escenarios, donde la prioridad de los elementos que intervienen en el lazo de producción varía según el impacto que tengan sobre el factor de recobro, por consideraciones técnicas adicionales como situaciones de contingencia o requerimientos específicos de los ingenieros de producción.
- La identificación del modelo de comportamiento de producción de un pozo bajo el accionar de inyección de levantamiento de flujo continuo.
- La búsqueda de la mejor distribución del gas disponible para inyección maximizando la producción de crudo en el sistema en estudio.

1.3. Justificación.

En la actualidad la tasa de inyección, para el método de levantamiento artificial por gas, es calculada por los ingenieros de producción de forma analítica en base a las curvas de rendimiento de cada pozo en forma individual. El gas de inyección es un recurso global y se distribuye entre la población de pozos asistidos por esta técnica, donde obtener el máximo beneficio, se convierte en una tarea compleja debido a que se tienen múltiples soluciones disponibles [Maggiolo, 2005].

Adicionalmente, hay que tener en cuenta las situaciones de contingencia que se presentan en las plantas compresoras de gas. Si el gas disponible para inyección es limitado y el tiempo de respuesta ante una baja considerable de presión debe ser mínimo, se deben hacer ajustes de las tasas de inyección. Dichos ajustes ya están preestablecidos en los manuales de contingencias y son una de las combinaciones posibles para

la distribución del gas, pero no necesariamente se tratan de las soluciones más convenientes. [Queipo, N. and Guevara, F., 2000].

La respuesta inmediata y la efectiva distribución de los recursos permiten a los ingenieros de optimización la toma de decisiones de manera confiable y oportuna mejorando los tiempos de respuesta y evitando pérdidas en la producción.

El modelo de optimización planteado en esta investigación, el cual está basado en computación evolutiva tiene la finalidad de generar una distribución del gas de inyección que permita obtener el máximo beneficio y que mejor se adapte a la situación actual. Dada la naturaleza compleja del problema y las múltiples variables involucradas en el lazo de producción, resulta conveniente la aplicación de algoritmos evolutivos, que no requieren conocimientos específicos del problema a resolver y son extendibles a problemas de objetivos múltiples con espacios de búsquedas grandes.

1.4. Delimitación de la Investigación y alcance.

En la presente investigación se utilizaron datos de 21 pozos pertenecientes a la Estación de Flujo 1-12, de la Unidad de Explotación LAGOMAR de PDVSA, como caso de estudio para la estrategia de optimización a implantar, sin embargo, es extendible a campos con varias estaciones de flujo involucradas, siempre que los pozos esten asistidos por levantamiento artificial con gas.

1.5. Objetivos.

El problema planteado anteriormente se desglosa en objetivos generales y objetivos específicos de la investigación.

1.5.1. Objetivo General.

Proponer un método basado en computación evolutiva que permita obtener la máxima producción posible a partir de una distribución eficiente de los recursos limitados necesarios para la explotación mediante en el método de levantamiento artificial por gas.

1.5.2. Objetivos Específicos.

1. Estudiar el proceso de producción de crudo con Levantamiento artificial por gas y las diferentes técnicas de computación evolutiva para la realización del modelo.
2. Definir las variables que influyen en el comportamiento del proceso de producción de petróleo asistido mediante inyección de gas y que son relevantes en la formulación del modelo de optimización.
3. Identificar y definir el modelo de optimización del campo en estudio.
4. Generar un algoritmo evolutivo de optimización de producción en pozos con levantamiento artificial por gas.
5. Realizar las pruebas con data en tiempo real para la validación del modelo.
6. Analizar los resultados obtenidos y compararlos con datos históricos.

1.6. Metodología.

Para cumplir con los objetivos descritos, se planteó un desarrollo cronológico de distintas tareas, orientadas al desarrollo del algoritmo evolutivo, las cuales son resumidas a continuación:

1. **Revisión Bibliográfica.**
2. **Identificación de un modelo de pozo.** Consiste en la creación de un modelo con el propósito de precisar y simular el comportamiento de las variables que afectan el proceso en estudio.
3. **Creación de un Modelo de Optimización.** Que es una representación matemática del problema que se desea resolver. Se trata de un modelo neuronal multicapa desarrollado utilizando la caja de herramientas de redes neuronales del lenguaje matemático MATLAB.
4. **Desarrollo del Algoritmo Evolutivo.** Capaz de generar un conjunto de soluciones aceptables al problema de optimización planteado, implantado en el lenguaje matemático MATLAB.
5. **Análisis de los Resultados.** Con la finalidad de validar el algoritmo evolutivo y poder emitir las conclusiones y recomendaciones del presente trabajo.
6. **Redacción del Informe de Proyecto de Grado.** Utilizando el procesador de textos Latex.

1.7. Resultados Esperados.

El propósito es obtener una matriz de datos, en las que estén identificados los valores adecuados de inyección de gas y sus respectivas tasas de producción para cada uno de los pozos que son objeto de estudio en esta investigación.

1.8. Organización del documento.

El documento está organizado en 5 capítulos, de la siguiente manera:

En el capítulo 1, se identifica el problema, los objetivos, los antecedentes, la justificación, los métodos y herramientas a utilizar, los resultados esperados y se delimita el problema.

En el capítulo 2, se muestra todo el marco teórico requerido para la elaboración del modelo de optimización del método de levantamiento artificial por gas basado en técnicas de computación evolutiva.

En el capítulo 3, se explica el modelo de optimización y se desglozan los algoritmos desarrollados para resolver el problema planteado y las diferentes técnicas utilizadas con este fin.

En el capítulo 4, se muestran los resultados obtenidos de las pruebas realizadas con el algoritmo evolutivo desarrollado.

En el capítulo 5, se explican las conclusiones generadas apartir del análisis de los resultados obtenidos y se plantean recomendaciones para dar continuidad a esta investigación.

Capítulo 2

MARCO TEÓRICO

En este capítulo se hace una breve descripción de los diferentes mecanismos de recuperación petróleo y de los componentes del lazo de explotación petrolera, con el propósito de estudiar los elementos involucrados. Se describe el funcionamiento del método de levantamiento artificial por gas y las formas de optimizar la energía disponible. Posteriormente, se presentan algunos tópicos como la optimización multi-objetivo y se da una breve reseña sobre las redes neuronales y los algoritmos evolutivos en su enfoque mono y multi-objetivo, haciendo hincapié en los conceptos claves en el desarrollo de este trabajo, con el propósito de establecer un marco conceptual para el problema que se plantea.

2.1. MECANISMOS DE RECUPERACIÓN DE PETRÓLEO.

En los yacimientos petroleros que se encuentran a grandes distancias por debajo de la superficie de la tierra el petróleo se encuentra afectado por la presión de las rocas que lo rodean o de los acuíferos presentes. Cuando un pozo es perforado, la presión del yacimiento se libera y los fluidos se dirigen hacia el punto donde ésta sea menor. Para controlar esa presión se crea un tubería hasta el fondo y luego se cementa (completación). El diferencial

de presión entre el yacimiento y la tubería representa la energía que hace que el pozo produzca fluidos. Mientras mayor sea la diferencia entre las dos presiones, mayor será la energía y mayor será la tasa de producción. Si se igualan la presión del yacimiento y la presión dentro de la tubería o dentro del pozo, no habrá más flujo del yacimiento hacia la superficie [Barberii, 1998].

La extracción de petróleo y gas puede hacerse utilizando sólo la energía del yacimiento. Cuando la presión es suficiente para llevar el fluido hasta la superficie, decimos que el pozo produce por *flujo natural*. La capacidad de producción del pozo en forma natural decrece a través del tiempo bien sea por que la energía del yacimiento disminuye sustancialmente y/o la capacidad de producción del pozo es menor o por que la columna de fluido se hace cada vez más pesada debido a un aumento del nivel de agua en el pozo [Aldana, V. and Salas, R., 2001].

Existen diversos métodos que permiten la recuperación de crudo en un pozo cuando la energía de éste ha disminuido:

- **Recuperación Primaria o convencional:** Son métodos de levantamiento artificial que asisten la producción sin invadir el yacimiento, entre los cuales destacan el bombeo electrosumergible, el bombeo mecánico, el bombeo de cavidad progresiva y el método de levantamiento artificial por gas, que es de principal interés en esta investigación por lo que será descrito con detalle en secciones posteriores.
- **Recuperación Secundaria:** Es la extracción de fluidos mediante la inyección de los mismos fluidos presentes en el yacimiento (gas y agua). Generalmente es aplicado posterior al método de recuperación primaria pero también se puede hacer de forma simultánea.
- **Recuperación Terciaria o Mejorada:** Consiste en alterar las propiedades físico-químicas del fluido en el yacimiento mediante la inyección de sustancias químicas

como dióxido de carbono y nitrógeno.

A partir del método de explotación de cada pozo se determina la tasa óptima de producción y se calcula la energía requerida para el levantamiento [Charrouf, 2001].

2.2. LEVANTAMIENTO ARTIFICIAL POR GAS (LAG).

Consiste en inyectar gas presurizado en determinado punto de la tubería de producción (no directamente en el yacimiento), de forma tal que al mezclarse con el crudo se eleve la presión del fluido, disminuya la viscosidad y el flujo se desplace con facilidad hacia la superficie (Ver figura 2.1). El gas inyectado reestablece el diferencial entre el yacimiento y la columna de crudo de la línea de producción [Zamora, 1985].

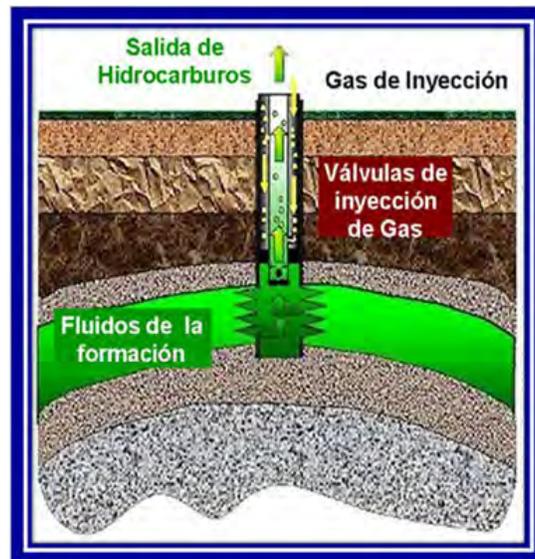


Figura 2.1: Levantamiento Artificial por Gas (LAG)

Para poner en funcionamiento éste método, se requieren únicamente dos clases de equipos de subsuelo; la válvula de levantamiento artificial por gas y el mandril de subsuelo. La cantidad de mandriles y válvulas requeridas dependerá fuertemente de la pre-

sión de inyección disponible. Los mandriles son tuberías especiales que conectan a la válvula con la tubería de producción a la profundidad requerida y la mantienen en su lugar [Charrouf, 2001].

2.2.1. Tipos de Sistemas de Levantamiento Artificial por Gas.

Se distinguen dos mecanismos de inyección de gas:

1. **Flujo Continuo:** Se considera una extensión del método de producción por flujo natural ya que complementa la energía del yacimiento mediante la inyección continua de gas en la columna de producción (figura 2.2a). El gas se desplaza hacia la superficie y se expande reduciendo la densidad del fluido progresivamente. El método resulta eficiente y menos costoso en pozos que pueden ser mantenidos con bajos niveles de gas de inyección [Yacimientos de Gas, 2008].
2. **Flujo Intermitente:** Está compuesto por una válvula calibrada, que inyecta cíclica e instantáneamente un alto volumen de gas comprimido en la tubería de producción, con el propósito de desplazar, hasta la superficie la columna o tapón de fluido proveniente del yacimiento (figura 2.2b).

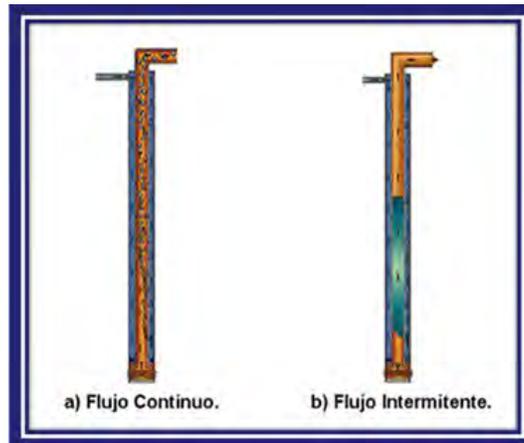


Figura 2.2: Tipos de LAG.

2.2.2. Ventajas y Desventajas del Levantamiento Artificial por Gas.

■ Ventajas:

1. Puede soportar grandes volúmenes de sólidos sin presentar daños en la instrumentación del sistema.
2. Las instalaciones de superficie son discretas por lo que pueden estar cerca de las poblaciones urbanas, también son aplicables mar adentro.
3. La fuente de inyección de gas puede estar lejos del sistema.
4. Permite obtener presiones del pozo y gradientes de forma sencilla.
5. La inversión inicial requerida para los equipos del subsuelo es menor en comparación con otros métodos de levantamiento artificial y los costos de operación son generalmente los menores del mercado.
6. Es uno de los métodos de levantamiento más flexible debido a que su instrumentación permite levantar volúmenes altos y bajos de crudo, según se requiera y sin realizar cambios significativos en el sistema.

7. Puede pasar de continuo a intermitente y viceversa de forma rápida.
8. El número relativamente pequeño de partes móviles en las válvulas de levantamiento artificial por gas, le permite una vida de servicio muy larga en comparación con otros sistemas de levantamiento artificial.
9. Cuando las instalaciones requieren servicio, éste puede hacerse con unidades de cable.
10. El método no se ve afectado de manera adversa por la desviación del hoyo.

■ **Desventajas:**

1. El gas presurizado es un recurso limitado y de disponibilidad variable.
2. Resulta costoso aplicarlo a campos pequeños, o a pozos unitarios si se requiere el equipo de compresión.
3. Resulta deficiente para levantar crudos viscosos.
4. Presenta problemas graves relacionados con la hidratación y gases congelados.
5. No puede asistir la producción de pozos profundos hasta su abandono de forma efectiva.
6. El casing debe soportar la presión del levantamiento.
7. La seguridad de los empleados se convierte en problema cuando se trabaja con gas de alta presión.

2.2.3. Descripción del Lazo de Producción Petrolera con Levantamiento Artificial por Gas.

El proceso de producción petrolera requiere un conjunto de instalaciones que permitan la extracción, tratamiento, distribución y transporte de hidrocarburos y sus componentes principales son descritos a continuación:

Pozo: Tiene la función de extraer los hidrocarburos desde el yacimiento hasta la superficie. El pozo está compuesto por un hoyo, que es una perforación hecha desde la superficie hasta el último estrato productor denominado “fondo del hoyo”. En la superficie se encuentra el “cabezal”, en donde se coloca toda la instrumentación para controlar el pozo desde superficie. Dentro del hoyo se introduce una tubería de revestimiento, generalmente elaborada en acero, denominada “*casing*”, en la cual se introduce la tubería de producción denominada “*tubing*”, que es por donde se extrae el fluido. Estos elementos se muestran en la figura 2.3.

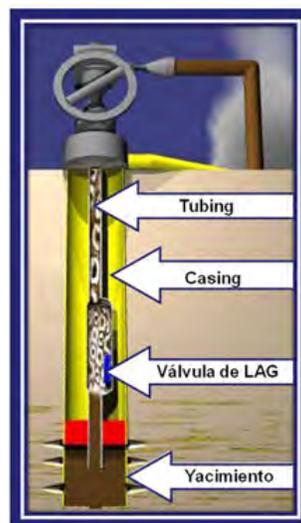


Figura 2.3: Estructura de un pozo con LAG. Tomado de [Industria Petrolera, 2008].

Estaciones de Flujo: Son un conjunto de instalaciones en las que tienen lugar algunos de los procesos fundamentales del lazo de producción petrolera, los cuales se describen a

continuación:

- **Recibo:** Corresponde a la entrada de la estación de flujo y consiste en la recolección del fluido multifásico proveniente de los diferentes pozos asociados a la estación de flujo.
- **Separación crudo/gas:** Consiste en la separación del fluido multifásico proveniente de los pozos, es decir, se separa el crudo del gas por medio de procesos mecánicos.
- **Medida de pozos:** Se refiere a las pruebas de producción ejecutadas a cada pozo asociado a la estación de flujo con el fin de determinar su nivel de productividad, obteniendo el flujo de gas, flujo de líquido y el corte de agua [González, 2008].

Plantas Compresoras: En estas plantas se recibe el gas a baja presión proveniente de las estaciones de flujo y se procede a comprimirlo para aumentar su presión. El gas presurizado es requerido para múltiples usos, entre los cuales se encuentra la inyección en los pozos asistidos por LAG.

Múltiples de Levantamiento Artificial por Gas (MLAG): En estas instalaciones se recibe el gas presurizado proveniente de las plantas compresoras para luego ser distribuido en cuotas de gas de inyección a cada pozo asistido por LAG.

Patio de Tanques: En estas instalaciones se llevan a cabo las labores de almacenamiento de crudo y el suministro hacia refinerías y puertos. Se realiza el tratamiento físico químico para la separación del agua y la eliminación de sustancias indeseables en el crudo, además se realiza el cálculo de la producción neta de crudo de la unidad de explotación asociada [González, 2008].

Estos componentes hacen posible la ejecución de las distintas funciones del proceso de producción y extracción de hidrocarburos de pozos asistidos por LAG, el cual está formado por diferentes etapas, interrelacionadas entre sí y que modelan el siguiente ciclo:

La planta compresora recibe el gas de baja presión procedente de los separadores ubicados en las estaciones de flujo, comprimiéndolo hasta la presión establecida para la entrega. Este gas de alta presión viaja a través de tuberías hasta llegar a los múltiples de levantamiento artificial por gas (MLAG) en donde se distribuye a los diferentes pozos. El caudal de inyección pasa a través de la tubería externa denominada casing llegando a las válvulas de subsuelo o mandriles de inyección de gas. Estas válvulas están calibradas para actuar a una presión preestablecida menor a la que debería llegar el gas de inyección produciéndose así el levantamiento del gas y crudo hacia la superficie a través de la tubería de producción denominada tubing hasta llegar a las estaciones de flujo [Charrouf, 2001]. De allí, se separan las fases de gas y líquida enviando el crudo a los patios de tanques en tierra y el gas recolectado de vuelta a la planta compresora, cumpliendo así el ciclo de producción que se ilustra en la figura 2.4:



Figura 2.4: Proceso de Producción de Crudo asistido con LAG.

La Unidad de Explotación LAGOMAR, se encuentra ubicada en el Lago de Maracaibo, cuenta con una estructura de 5 Plantas Compresoras de Gas, 21 Estaciones de Flujo y un Múltiple de Gas. En la figura 2.5 se muestra el diagrama de la red de transmisión y distribución de gas de alta presión de la Unidad de Explotación LAGOMAR.



Figura 2.5: Sistema de Manejo de Gas de Alta Presión.

Es este trabajo de investigación se toman en consideración pozos que ya se encuentran en producción mediante LAG. En cada escenario posible de producción, los pozos deben contar con la energía necesaria para fluir en forma óptima. Para esto, se debe tener en cuenta la energía disponible en el sistema y establecer la relación que genere el máximo retorno

económico del uso de esta energía.

2.3. OPTIMIZACIÓN DE LA ENERGÍA DISPONIBLE.

En la actualidad el gas disponible se encuentra limitado. Su producción ha sido reducida debido al avanzado estado de agotamiento en que se encuentran los yacimientos, al incremento en el consumo de gas para levantamiento artificial y en los requerimientos de terceros. Es necesario controlar el uso del gas disponible para poder maximizar su rendimiento económico, sin afectar los compromisos de producción adquiridos.

En el Levantamiento Artificial por Gas es posible determinar las condiciones óptimas de operación a partir de la *Curva de Rendimiento del Pozo*, la cual nos permite estimar la cantidad de gas óptima requerida para maximizar la tasa de producción de fluidos (producción/ inyección). Para obtener estas curvas es necesario crear el modelo de cada pozo, utilizando herramientas de simulación [Charrouf, 2001].

Las curvas de rendimiento proporcionan un modelo de pozo que permite estimar la tasa de producción dada una tasa de inyección específica. En la figura 2.6 se observa el siguiente comportamiento: a medida que la tasa de inyección de gas aumenta, la producción también aumenta hasta alcanzar un máximo. Incrementos adicionales en la inyección causarán una disminución en la producción. Al inyectar gas adicional el gradiente de presión continuará disminuyendo hasta un valor después del cual, más gas causará un aumento en el gradiente de presión, debido a fricción adicional y posiblemente efectos de energía cinética.

Existen criterios de optimización que permiten jerarquizar el consumo de energía en situaciones de baja disponibilidad, uno de los cuales es realizar listas de pozos jerarquizados por su rendimiento de gas de inyección, que facilitan el cierre de pozos de alto con-

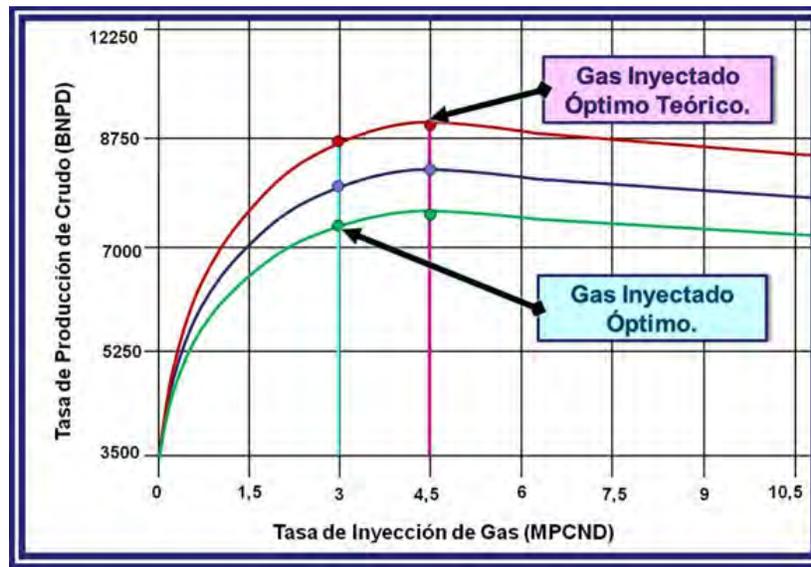


Figura 2.6: Curvas de Rendimiento para diferentes tasas de inyección de gas.

sumo de gas de levantamiento con baja producción de líquido para balancear el sistema. Otro indicador para jerarquizar es la relación del consumo eléctrico con respecto a la tasa de producción [Maggiolo, 2005].

En resumen, para la optimización de la energía disponible se requiere la ejecución de las siguientes actividades:

- Realizar análisis de la capacidad de energía disponible, mediante curvas de rendimiento y determinar requerimientos de energía por pozo y grupo de pozos, según el método de producción.
- Elaborar un balance de energía del sistema.
- Distribuir la energía disponible según la estrategia para el manejo de gas y distribución eléctrica en el lazo de producción.

2.4. OPTIMIZACIÓN MULTI-OBJETIVO.

En las distintas áreas del conocimiento y en el quehacer humano es común que se presenten situaciones en las que se requiere encontrar soluciones, mejorar resultados o tomar decisiones que normalmente son resueltas de forma inconsciente pero que pueden ser planteadas como problemas de optimización, lo que la convierte una de las áreas de las matemáticas con mas aplicaciones en la vida real.

Los problemas de optimización se caracterizan a través de los siguientes elementos:

Variables de Decisión: Son una abstracción de los criterios relevantes del problema, representados mediante valores numéricos que se modifican para dar solución al problema.

Función Objetivo: Son las relaciones que deben cumplir las variables de decisión expresadas como funciones calculables, es necesaria al menos una y el resultado de su evaluación es el que se desea optimizar.

Las restricciones: Son las desigualdades o ecuaciones que delimitan el conjunto de valores que se pueden asignar a las variables de decisión para que la solución se considere factible.

En este contexto, la *optimización* se define como el proceso por el cual se busca minimizar o maximizar el valor de una función objetivo, eligiendo sistemáticamente los valores de las variables de decisión, dentro de un espacio de búsqueda permisible [Landa, 2008].

En algunos problemas de optimización se considera la existencia de un solo criterio u objetivo al definir modelos complejos (optimización mono-objetivo), sin embargo, existen problemas que involucran varios objetivos que no pueden ser combinados de manera simple en una sola función.

Al paradigma que permite considerar todas las funciones objetivos existentes en un problema de optimización recibe el nombre de *Optimización Multi-objetivo*.

En la ingeniería, en las ciencias de la computación y en la industria en general, la mayoría de los problemas que se presentan requieren optimización simultánea de objetivos múltiples, los cuales pueden ser no comparables o estar en conflicto mutuo, lo que ocasiona que resulten afectados algunos objetivos al tratar de mejorar otros. Por lo tanto, la solución a un problema multi-objetivo no es única, se trata de un conjunto de posibles soluciones con la misma relevancia, es decir, donde no es posible que una solución sea mejor que otra [Fonseca, C. and Fleming, P., 1995].

El problema de la Optimización Multi-objetivo es definido por *Osyczka* en 1985 [Mezura, 2001], de la siguiente manera:

“Encontrar un vector de variables de decisión que satisfaga las restricciones dadas y optimice un vector de funciones cuyos elementos representan las funciones objetivo. Esas funciones forman una descripción matemática de los criterios a optimizarse y generalmente se encuentran en conflicto entre sí. Por lo tanto, el término optimizar significa encontrar las soluciones que darían valores aceptables para todas las funciones objetivos.”

Formalmente el problema de la optimización multi-objetivo se representa como [Mezura, 2001]:

$$\vec{X}_j = [x_1; x_2; x_3; \dots; x_n]^T \text{ para } j = 1, 2, 3, \dots, n \quad (2.1)$$

Para n parámetros, encontrar el vector de soluciones o variables de decisión.

Sujeto a:

- p restricciones de igualdad:

$$h_i(\vec{x}) = 0; \text{ para } i = 1, 2, 3, \dots, p. \quad (2.2)$$

- g restricciones de desigualdad:

$$g_i(\vec{x}) \leq 0; \text{ para } i = 1, 2, 3, \dots, g. \quad (2.3)$$

Optimizando el vector de k funciones objetivo.

$$\text{Maximizar o minimizar } f_k(\vec{x}) = [f_1(\vec{x}); f_2(\vec{x}); \dots; f_n(\vec{x})]^T \text{ para } k = 1, 2, \dots, n. \quad (2.4)$$

El conjunto de vectores de decisión \vec{X}_j que satisfacen las restricciones del modelo recibe el nombre de **Conjunto Factible S**:

$$S = \{ \vec{x} \in \vec{X} \mid g(\vec{x}) \leq 0 \cap h(\vec{x}) = 0 \} \quad (2.5)$$

La imagen de S en el espacio de las funciones objetivo está definido por $Z = f(S)$. Es importante resaltar que en este tipo de problemas intervienen dos espacios de búsqueda diferentes, los cuales son:

1. El espacio n-dimensional de las variables de decisión (llamado también espacio genotípico), en el cual cada eje coordenado corresponde con cada componente del vector \vec{X}_j .

2. El espacio k -dimensional de las funciones objetivo (llamado también espacio de criterios, o espacio fenotípico), en el cual cada eje coordenado corresponde con cada componente del vector $f_k(\vec{x})$.

Aunque los espacios de las variables de decisión y el de los objetivos se encuentran relacionados por un mapeo directo entre ellos, este mapeo no es lineal en la mayoría de los casos y las propiedades de los dos espacios no son similares. Por ejemplo, la proximidad entre dos soluciones en un espacio no significa que exista una proximidad similar en el otro espacio [Zitzler, E. et al., 2004].

Existen tres situaciones que se pueden presentar al momento de optimizar objetivos múltiples:

- Minimizar todas las funciones objetivo.
- Maximizar todas las funciones objetivo.
- Minimizar algunas y maximizar las funciones objetivo restantes

Por simplicidad, se suelen considerar sólo problemas del primer tipo (minimizar todas las funciones objetivo), transformando las funciones objetivo, en caso de ser necesario.

2.4.1. Optimalidad de Pareto.

La noción de óptimo en problemas multi-objetivo fue originalmente propuesta por Francis Y. Edgeworth en 1881 y generalizada por Wilfredo Pareto en 1896, por lo que lleva su nombre [Coello, 2003].

La definición formal de Óptimo de Pareto es la siguiente:

Un vector de variables de decisión $\vec{x} \in F$ (donde F es la zona factible) es un óptimo de Pareto si no existe otro $\vec{x} \in F$ tal que:

$$f_i(\vec{x}) \leq f_i(\vec{x}^*) \text{ para toda } i = 1, 2, \dots, k \text{ y } f_j(\vec{x}) < f_j(\vec{x}^*) \text{ para al menos una } j.$$

Es aquel vector de variables en el cual no se pueden mejorar las soluciones del problema en una función objetivo sin empeorar cualquiera de las demás. Esto no nos proporciona una sola solución, sino que se obtiene un conjunto de soluciones llamado Conjunto de Óptimos de Pareto [Coello, 2003].

2.4.2. Dominancia de Pareto.

Es un concepto comúnmente utilizado para comparar dos soluciones y determinar si una domina a otra o no. Una definición formal de Dominancia de Pareto se muestra a continuación:

Un vector $\vec{u} = (u_1, \dots, u_k)$ domina a otro $\vec{v} = (v_1, \dots, v_k)$ si y solo si u es parcialmente menor que v .

En otras palabras, para que una solución domine a otra, ésta necesita ser estrictamente mejor en al menos un objetivo, y no peor en ninguno de ellos. Matemáticamente representamos las condiciones necesarias y suficientes para que una solución \vec{X}_a domine a una solución \vec{X}_b (para el caso de minimización) de la siguiente forma:

- La solución \vec{X}_a no es peor que \vec{X}_b en todos sus objetivos, o:

$$f_i(\vec{x}_a) \leq f_j(\vec{x}_b), \forall i \in [1, 2, \dots, k].$$

- La solución \vec{X}_a es estrictamente mejor que \vec{X}_b en al menos un objetivo, o:

$$f_i(\vec{x}_a) < f_j(\vec{x}_b), \exists i \in [1, 2, \dots, k]$$

Si alguna de estas condiciones no se cumple la solución \vec{X}_a no domina a \vec{X}_b [Eficiencia de Pareto, 2008]. La forma matemática de representar la dominancia y no dominancia entre las soluciones es la siguiente [Zitzler, E. et al., 2004]:

- $\vec{X}_a < \vec{X}_b$: \vec{X}_a domina a \vec{X}_b .
- $\vec{X}_a < \vec{X}_b$: \vec{X}_a domina parcialmente a \vec{X}_b .
- $\vec{X}_a \sim \vec{X}_b$: \vec{X}_a es indiferente a \vec{X}_b , son vectores no dominados entre sí.

2.4.3. Frente de Pareto.

Es la representación del conjunto de soluciones no dominadas, que se encuentran en los límites de la zona factible (Ver figura 2.7).

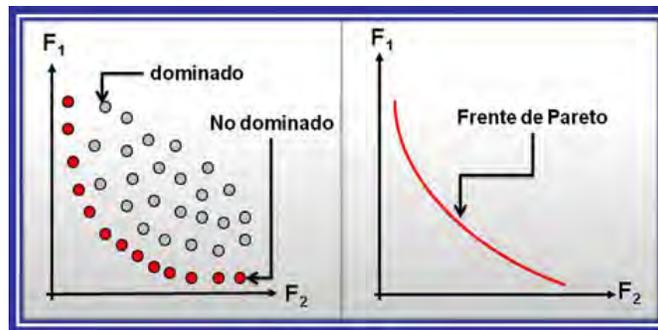


Figura 2.7: Frente de Pareto.

Ahora bien, para un problema multi-objetivo dado $\vec{f}(x)$ y un conjunto de óptimos de Pareto P^* , el frente de Pareto (FP^*) se expresa así:

$$FP^* = \{ \vec{f} = [f_1(x), \dots, f_k(x)] \mid x \in P^* \} \quad (2.6)$$

No existe forma de encontrar una expresión analítica para esa línea o superficie que corresponde a las soluciones no dominadas; la mejor forma es evaluar todos los puntos de la zona factible Ω , obtener todos los $\vec{f}(x)$ para toda $\vec{X} \in \Omega$ y cuando se tiene un número considerable de ellos, es posible determinar las soluciones no dominadas y producir el Frente de Pareto [Mezura, 2001].

En la figura 2.8 se muestra el problema de optimización multiobjetivo y sus componentes.

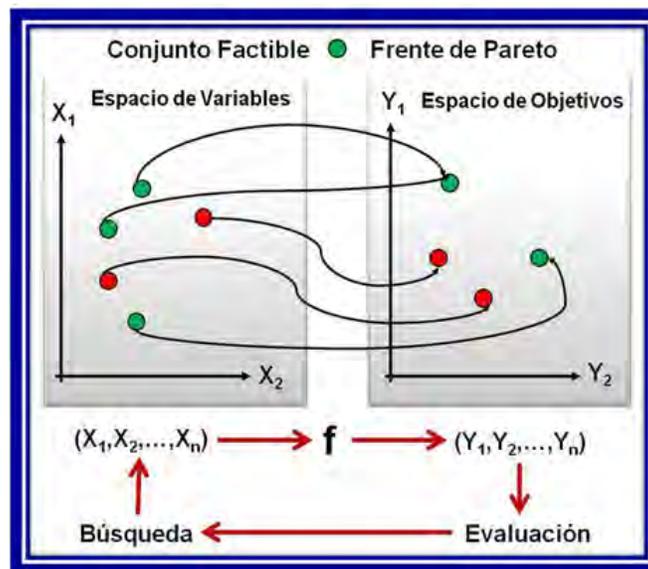


Figura 2.8: Ilustración del Problema de Optimización Multiobjetivo.

Desde el punto de vista de que todas las soluciones que representan un óptimo de Pareto deben tener la misma importancia, es necesario encontrar el mayor número de soluciones posible, que sean óptimos de Pareto. Por consiguiente, se pueden resumir dos propósitos fundamentales de la optimización multi-objetivo:

1. Encontrar un conjunto de soluciones lo más cercana posible al conjunto de óptimos de Pareto ya que el resto de las soluciones carecen de utilidad.
2. Encontrar un conjunto de soluciones lo más diversas posibles. Se desea obtener solu-

ciones que además de pertenecer al conjunto de óptimos de Pareto, deben también encontrarse distribuidas lo más uniformemente posible. De esta forma se puede asegurar que se tiene un buen conjunto de soluciones.

Las soluciones se clasifican como deseables y no deseables tomando en cuenta que tan próximas se encuentran al Frente de Pareto del problema de optimización. Se obtienen dos conjuntos de soluciones; las que se encuentran mejor distribuidas son preferidas sobre aquellas que se encuentran muy cercanas entre sí, inclusive cuando ambos conjuntos de soluciones están sobre el frente de Pareto.

La mayoría de los problemas de optimización multi-objetivo del mundo real se caracterizan por su alta complejidad, alta dimensionalidad del espacio de búsqueda, discontinuidad en las funciones objetivo y multimodalidad. Estas características hacen que las numerosas técnicas clásicas de optimización que la investigación de operaciones ha desarrollado presenten fuertes limitantes al enfrentar este tipo de problemas, entre las cuales se pueden listar las siguientes [Landa, 2008]:

1. Se requieren múltiples ejecuciones del algoritmo para encontrar varias soluciones del conjunto de óptimos de Pareto, lo que implica tiempos de cómputo altos.
2. La mayoría de las técnicas clásicas requieren información previa sobre el dominio del problema que se desea resolver, lo que no siempre es posible cuando se trata de problemas multi-objetivo debido a la alta complejidad.
3. Algunos algoritmos son sensibles a la forma o continuidad del frente de Pareto.
4. La dispersión de las soluciones del Frente de Pareto depende de la eficiencia del optimizador mono-objetivo.

Por tal motivo, es indispensable la búsqueda de enfoques alternativos a las técnicas clásicas para resolver este tipo de problemas. Algunos de los componentes de la Inteligencia

Artificial satisfacen estos requerimientos y ofrecen una solución aceptable a la problemática planteada en esta investigación, a continuación se describen las metodologías pertenecientes a esta área que son de interés en el presente trabajo.

2.5. INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL (IA).

La Inteligencia Artificial (IA) surgió como resultado de varias investigaciones en las áreas de psicología cognitiva y lógica matemática. Comprende la construcción de algoritmos y sistemas computarizados que manifiestan cierta forma de inteligencia, capaces de llevar a cabo actividades complejas realizadas por el humano, tales como comprensión del lenguaje natural, reconocimiento de imágenes, reconocimiento simbólico, entre otras [García, 2004].

En todos los problemas complejos de la IA, es necesario manejar de forma adecuada la información de la situación real que se quiere solventar y representarla de manera que el algoritmo la interprete de forma correcta. Esto se lleva a cabo mediante la representación del conocimiento o el aprendizaje de máquina, que es el método construido por el sistema de IA para capturar los elementos esenciales del dominio de un problema, lo modifica en base a su entorno y mejora su comportamiento en base a la experiencia adquirida al realizar la misma tarea en repetidas ocasiones. La IA maneja tres paradigmas fundamentales para la manipulación del conocimiento [Felix, 2008]:

- **Programación Heurística:** Es una forma de trabajo que permite resolver problemas que no tienen una solución aparente y de los cuales no se tiene mucha información. Facilita la búsqueda de soluciones a través de procedimientos que simulan procesos mentales exigentes. Algunos de estos algoritmos son capaces de aprender de su propia experiencia. En el área de optimización, las técnicas heurísticas permiten aproximar la solución de problemas que no se adaptan a ninguna de las técnicas

clásicas. Se aproximan de forma intuitiva y ordenada a la mejor solución (o conjunto de soluciones), aunque no garantizan llegar al óptimo, son adaptables al tipo de problema; es decir, que para cierto tipo de problemas existen heurísticas que dan buenos resultados, sin embargo, no existe una heurística ideal para resolver cualquier problema [Heurística, 2008].

- **Redes Neuronales Artificiales:** Es una representación abstraída del modelo neuronal del cerebro humano, que emula su comportamiento. Su aplicación ha sido provechosa en procesos asociados con las capacidades de aprendizaje y en múltiples áreas como el reconocimiento de patrones y la identificación de sistemas; constituyen un elemento importante de esta investigación y son descritas con detalle en la siguiente sección [Red Neuronal Artificial, 2008].
- **Evolución Artificial:** Mediante este enfoque se hace una analogía del proceso de evolución biológica en la resolución de problemas complejos, mediante mecanismos de reproducción, mutación y cruce como ocurre con los organismos vivos [Computación Evolutiva, 2007]. Algunas de las técnicas aplican el paradigma heurístico y generalmente son usadas para la optimización de procesos. La Computación Evolutiva es un claro ejemplo de este enfoque y constituye un elemento clave en la solución del problema planteado en este trabajo, por lo que se explica con detalle en secciones posteriores.

2.6. REDES NEURONALES ARTIFICIALES.

En primer lugar, revisemos algunas definiciones de la neurona biológica presente en el cerebro humano, antes de intentar definir las redes neuronales artificiales.

2.6.1. La Neurona Biológica.

La neurona biológica es la célula nerviosa que constituye el elemento fundamental del sistema nervioso central del ser humano. Estas células ejecutan funciones de procesamiento y comunicación, son capaces de recibir y procesar señales provenientes de otras neuronas, generar y conducir impulsos nerviosos, y posteriormente retransmitirlos a otras neuronas. Los principales componentes de la neurona biológica son los siguientes [Aguilar, C and Rivas, F., 2001]:

- **Dendritas:** Son extensiones de fibras nerviosas y están implicadas en la recepción de los estímulos externos o de las señales emitidas por otras neuronas.
- **Cuerpo Celular:** También llamado Soma, es donde se almacena todo el contenido recibido por las dendritas. Si el nivel alcanzado por las señales de entrada es suficientemente grande, entonces la neurona se activará generando una señal de salida, la cual será suministrada a las otras neuronas por medio del axón.
- **Axón:** Son estructuras cilíndricas similares a las dendritas que corresponden a la salida de la neurona.

Las neuronas no almacenan información, es la intensidad de las interconexiones entre ellas lo que determina las acciones realizadas por una red neuronal. A las interconexiones entre el axón de una neurona con las dendritas de otra, o directamente al soma de otras neuronas, se le denomina sinápsis.

El proceso de activación neuronal es recurrente. Una neurona es activada por otra neurona y esta a su vez activa otras y así sucesivamente. La comunicación entre las neuronas ocurre como el resultado de transporte de señales químicas a través del axón, o sustancias a través de sinápsis; con la posterior absorción de estas señales por las dendritas de las neuronas receptoras. El proceso de aprendizaje puede ser visto como el ajuste apropiado

de las interconexiones sinápticas para guardar el conocimiento y las asociaciones deseadas a través de la experiencia. Esto explica la relación inversa que existe entre el número de neuronas y el conocimiento que poseen los seres humanos cuando nacen. En la figura 2.9 se ilustran los componentes de la neurona biológica [Aguilar, C and Rivas, F., 2001].

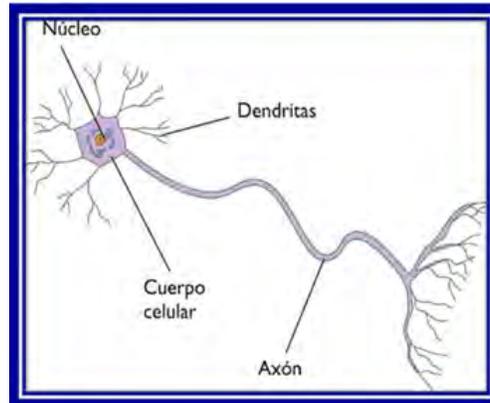


Figura 2.9: Partes de la Neurona Biológica.

2.6.2. La Neurona Artificial.

Desde 1960 cierto número de investigadores han intentado replicar el funcionamiento de las neuronas biológicas en la resolución de problemas matemáticos y el resultado ha sido la neurona artificial.

Las neuronales artificiales de la misma forma que las neuronas biológicas, poseen una unidad de procesamiento con un número de canales de entrada, cada uno de los cuales tiene un peso asociado, que indican las fuerzas de las conexiones sinápticas y las dendritas de la neurona, el cuerpo celular, cuya función es acumular todas las señales ponderadas recibidas, una función de activación “T” que determina el cambio de estado de inhibitorio a excitatorio de la neurona; y por último, el axón que es el canal de salida que emite la respuesta de la neurona ante los estímulos de las entradas [Aldana, V. and Salas, R., 2001].

En este orden de ideas, si tenemos X_i entradas, y las ponderamos multiplicándolas

por un peso W_i donde $i = 1, \dots, n$. Al llegar a la neurona todos los datos de las entradas, ponderadas por sus pesos son sumados. Esto se conoce como la Regla de Propagación y el resultado se denomina potencial sináptico. Cuando el resultado de la regla de propagación supera a cierto número, denominado umbral, entonces la neurona se activa y el número resultante de la regla de propagación se evalúa en la función de activación Γ [Aguilar, C and Rivas, F., 2001]. En la figura 2.10 se muestra un esquema de la neurona artificial y su analogía con la neurona biológica.

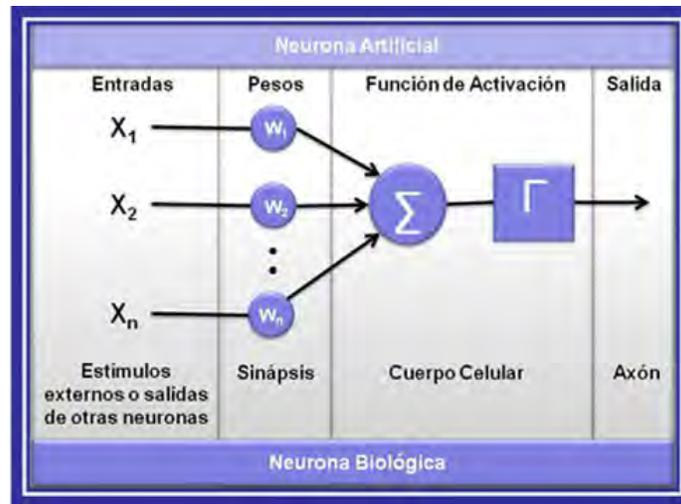


Figura 2.10: La Neurona Artificial y sus equivalentes biológicos.

2.6.3. Redes Neuronales Artificiales.

Una neurona artificial por sí sola, no tiene capacidad para realizar un proceso lógico, pero un conjunto de ellas sí.

Las redes neuronales artificiales son un conjunto de unidades que se encargan de realizar un procesamiento paralelo y distribuido de las señales presentadas a sus entradas y que tienen un mecanismo natural para guardar conocimiento proveniente de la experiencia y dar como resultado información importante relacionada con el proceso de estudio [Aldana, V. and Salas, R., 2001].

Entre las múltiples aplicaciones de las redes neuronales podemos mencionar: el reconocimiento de patrones, el análisis del lenguaje, la recuperación de datos, la robótica, el control, el análisis y modelado de procesos.

Las redes neuronales artificiales no son algorítmicas, ellas generan sus propias reglas, para asociar la respuesta a las entradas que recibe, es decir, aprende el comportamiento mediante ejemplos y de sus propios errores.

Los modelos de redes neuronales varían según las características estructurales y pueden ser clasificadas en dos grandes grupos o modelos [Aguilar, C and Rivas, F., 2001]:

- (a). **Modelos de redes en cascada:** En esta configuración, las neuronas son ordenadas en forma de capas, cuyas neuronas provienen de las salidas de las neuronas de la capa anterior, y cuyas salidas van a las neuronas de la capa siguiente. No existen interconexiones entre neuronas pertenecientes a la misma capa ni interconexiones de retroalimentación. Un ejemplo importante de esta configuración son las redes perceptrónicas multicapas.
- (b). **Modelos de redes retroalimentadas:** En este modelo, las salidas de las neuronas de una capa pueden estar interconectadas a las entradas de las neuronas de la misma capa o a entradas de neuronas de capas precedentes.

Por otro lado, las redes neuronales tienen la capacidad de aprender, mediante mecanismos de ajustes de la memoria a largo plazo, la cual se organiza para almacenar la información que posteriormente permitirá a la red reconocer y generalizar lo aprendido. Esto lo define la forma de ponderar las interconexiones neuronales y se conocen como formas de entrenamiento. Dependiendo del tipo de aprendizaje las redes neuronales se puede clasificar en [Aguilar, C and Rivas, F., 2001]:

- (a). **Redes entrenadas con supervisión:** En este tipo de aprendizaje se presentan los

patrones de entrada a la red y el respectivo resultado que debe tener en sus salidas. La red es capaz de ajustar los pesos de las neuronas de forma que a la presentación posterior de estos patrones la red responde con salida memorizada.

- (b). **Redes entrenadas sin supervisión:** No requiere información acerca de cuál debe ser la salida de la red ante la entrada presentada, la red se auto-organiza basada en la información local.

2.6.4. Redes Neuronales Multicapa.

Las redes perceptrónicas multicapa o redes multicapa están constituidas por un conjunto de capas de nodos conectadas en secuencia, conformando tres tipos de capas:

- **La Capa de entrada:** Es la capa en donde se coloca el vector de entradas a la red. Los nodos de esta capa no realizan ningún tipo de procesamiento, solo reciben la entrada y la distribuyen a las unidades de la capa oculta.
- **La Capa de salida:** Es la capa donde aparece el vector de salida que produce la red.
- **Las Capas ocultas:** Son las capas ubicadas entre la capa de entrada y la capa de salida, y su número puede variar. Sin embargo, el Teorema de Kolmogorov (1975), establece que existe una red perceptrónica multicapa con una sola capa oculta que puede aproximar cualquier proceso, con precisión arbitraria. Posteriormente, Hecht-Nielsen estableció como una cota que el número de unidades en la capa oculta está dado por $2N + 1$, donde N es el número de unidades de la capa de entrada [Aldana, V. and Salas, R., 2001].

El flujo de información en la red es unidireccional, y se produce desde la capa de entrada hasta la de salida como se muestra en la figura 2.11.

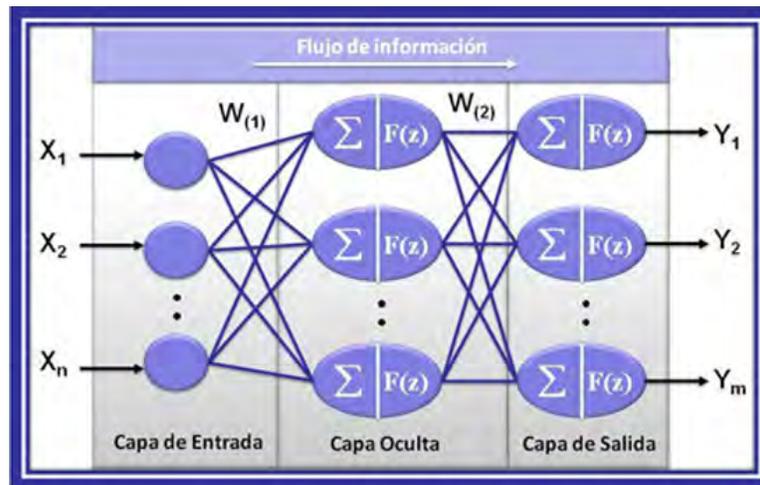


Figura 2.11: Red Neuronal Multicapa.

2.6.5. Algoritmo de Retropropagación.

La regla de entrenamiento para las redes multicapa recibe el nombre de retropropagación (Backpropagation en inglés), es un algoritmo supervisado que fue desarrollado por P. Werbos en 1974 y posteriormente popularizado por Rumelhart y sus colaboradores en 1986 [Redes de Retropropagación, 2008].

El Algoritmo de Retropropagación es un método de optimización basado en gradiente que busca minimizar una función del error de la red, propagándolo hacia atrás, desde la capa de salida hacia la capa de entrada, pasando por las capas ocultas intermedias y ajustando los pesos de las mismas [Redes de Retropropagación, 2008]. Dicho error se calcula como la diferencia entre la salida de la red y la salida deseada. Como cualquier método basado en gradiente, este algoritmo es susceptible a quedar atrapado en mínimos locales, por lo que se recomienda realizar varios entrenamientos con distintos pesos iniciales, y seleccionar el que presente el mejor desempeño.

Existen distintas versiones o reglas del algoritmo de retropropagación que pueden ser aplicadas, algunas mejoran significativamente el desempeño de la red como las realizadas

por Levenberg en 1944 y Marquardt en 1963.

2.6.6. Método de Levenberg - Marquardt.

Es un algoritmo de optimización en el que el método de iteración presenta una ligera modificación sobre el método tradicional de Newton. Está diseñado para proporcionar una convergencia rápida hacia el mínimo de una función de segundo orden sin tener que calcular la matriz de Hessianos. Tiene un excelente desempeño en el entrenamiento de redes neuronales donde el rendimiento de la red está determinado por el error medio cuadrático, que es el criterio más utilizado en las redes multicapa, en este caso la matriz de Hessianos y el gradiente de la función se pueden aproximar como:

$$H = J^T . J, \nabla_f = J^T . e \quad (2.7)$$

Donde J es la matriz de Jacobianos, e es la función de error, y ∇_f es el gradiente de la función del error. Entonces el algoritmo está dado por la ecuación:

$$X_i = X_{i-1} - \alpha (\lambda I - H_f)^{-1} . \nabla_f \quad (2.8)$$

Donde α y λ son positivos, I e H la matriz identidad y matriz de Hessianos respectivamente y X_{i-1} y X_i es la matriz de pesos actuales y la matriz de pesos a calcular [Bacpropagation, 2008].

Este método es usado generalmente para calcular los pesos en redes neuronales multicapa en donde el numero de pesos no supera los cien, en caso contrario para redes muy grandes el algoritmo requiere de una gran cantidad de memoria debido a las dimensiones de las matrices que debe calcular.

2.7. INTRODUCCIÓN A LA COMPUTACIÓN EVOLUTIVA (CE).

Durante muchos años la teoría más aceptada sobre el origen de las especies fue El Creacionismo la cual dice que Dios creó al cielo, la tierra y todas las especies que en ella habitan, cada una por separado y que las especies estaban jerarquizadas por Dios de tal manera que el hombre ocupaba el nivel superior al lado del creador. El descontento de algunos científicos con esta teoría dio lugar a los principios que sirven de base a los orígenes de la Computación Evolutiva.

El naturalista inglés Charles Darwin publicó en 1865 su libro titulado “El Origen de las Especies”, uno de los avances conceptuales más importantes del siglo XIX que sentó las bases de la teoría moderna de la evolución. Darwin afirmaba que la evolución se origina a través de cambios aleatorios de características hereditarias, combinados con un proceso de selección natural. Esta Teoría describe que a causa del problema de la disponibilidad de alimentos, los jóvenes miembros de las distintas especies compiten intensamente por su supervivencia. Los que sobreviven, que darán lugar a la siguiente generación, tienden a incorporar variaciones naturales favorables al proceso de selección natural, y estas variaciones se transmitirán a través de la herencia [Mezura, 2001].

La Teoría de la Selección Natural fue desplazada cuando el monje austriaco Gregor Johann Mendel (1822 - 1884) realizó una serie de experimentos con semillas durante un periodo prolongado y a partir de ellos enunció las leyes básicas de la herencia, que explican como van a ser las características de los descendientes a partir de las características de sus progenitores [Mezura, 2001]:

1. **Ley de la Uniformidad:** Describe que si se cruzan dos razas puras para un determinado carácter, los descendientes de la primera generación son todos iguales entre sí e iguales a uno de los progenitores.

2. **Ley de las Disyunción:** Establece que los caracteres recesivos, al cruzar dos razas puras, quedan ocultos en la primera generación, reaparecen en la segunda en proporción de uno a tres respecto a los caracteres dominantes.
3. **Ley de la Segregación Independiente:** Define que los caracteres son independientes y se combinan al azar.

En 1883 el Alemán August Weismann (1834-1914) formuló la Teoría del Plasma Germinal, según la cual el cuerpo se divide en células o tejidos de dos tipos, las células germinales (germoplasma) capaces de transmitir la información hereditaria y las células somáticas (somatoplasma) que no pueden transmitir nada.

Posteriormente como resultado de la fusión entre la selección natural de Darwin, las leyes de la herencia de Mendel y la hipótesis del Plasma Germinal propuesta por Weismann se originó el paradigma del Neo-Darwinismo, el cual establece que la vida en el planeta puede ser explicada a través de cuatro procesos estocásticos fundamentales; la reproducción, la mutación, la competencia y la selección. Esta teoría sirvió como inspiración en el desarrollo de las diversas técnicas de la computación evolutiva que existen en la actualidad [Santana, V. and Coello, C., 2002].

La Computación Evolutiva es un enfoque para abordar problemas complejos de búsqueda y aprendizaje a través de modelos computacionales de procesos evolutivos. Las implantaciones concretas de tales modelos se conocen como Algoritmos Evolutivos [Landa, 2008].

2.8. ALGORITMOS EVOLUTIVOS (AE).

Los Algoritmos Evolutivos son procedimientos adaptativos (probabilísticos y heurísticos) de optimización y búsqueda estocástica que hacen evolucionar a un conjunto de estructuras seleccionado de forma iterativa a las más adecuadas [Santana, V. and Coello, C., 2002].

2.8.1. Componentes de los Algoritmos Evolutivos.

En esta sección se presentan los aspectos mas resaltantes de los Algoritmos Evolutivos.

Población.

Es una colección de individuos con características genéticas comunes que representan las variables de decisión de las funciones objetivo del problema. En este sentido un individuo es una solución potencial al problema que se trata. Cada individuo contiene un cromosoma que es donde se encuentra la información genética.

La *aptitud* de un individuo es la evaluación de la función de aptitud e indica que tan bueno es el individuo (es decir, la solución al problema) con respecto a los demás. Usualmente, la función de aptitud es igual a la función objetivo del problema.

Representación.

Es la estructura de datos o *cromosoma* que representa a un individuo de la población, es decir, a las soluciones potenciales del problema. Normalmente se trata de un arreglo de enteros, donde cada posición representa un *gen* que codifica el valor de un solo parámetro

de la solución del problema. El valor que puede tomar cada gen se conoce como alelo.

Operadores Genéticos.

Son procedimientos que manipulan la información genética de la población para producir nuevos individuos vistos como variaciones de la población original. Los operadores genéticos más comunes en los algoritmos evolutivos son:

1. **Recombinación o cruce:** Es un procedimiento de combinación de cromosomas entre los individuos de una población. Consiste en segmentar a los padres en dos o más fracciones para intercambiar las partes y formar nuevos individuos. De esta forma se conservan los genes que nos permiten obtener los mejores resultados del problema. La recombinación se dedica a explorar las zonas más prometedoras del espacio de búsqueda del problema en estudio.
2. **Mutación:** Forma un nuevo individuo a partir de modificaciones pequeñas del contenido genético de un solo padre. Aplica un cambio a uno de los genes de un cromosoma elegido de forma aleatoria y produce individuos con pequeñas variaciones con respecto al individuo original. Permite la introducción de nuevo material cromosómico en la población.
3. **Selección:** Determina la probabilidad de elegir un individuo para que produzca descendencia por medio de la recombinación y la mutación. Se basa en el valor que determinan los individuos de su función de aptitud, la cual es consecuencia directa de la influencia del individuo en las funciones objetivo del problema, y sirve para determinar su supervivencia en la siguiente generación. El esquema de selección es una de las partes cruciales de un algoritmo evolutivo, puesto que sesga la búsqueda de manera que eventualmente se llegue a la solución óptima (o su proximidad) [Mezura, 2001].

2.8.2. Esquema General de los Algoritmos Evolutivos.

Los Algoritmos Evolutivos difieren unos de otros dependiendo de la representación adoptada por los individuos y de los esquemas que sean utilizados para implementar la evaluación de aptitud y los operadores genéticos.

En el inicio se genera una población de individuos, cada uno representando una solución potencial del problema. A continuación se desarrolla un proceso iterativo que transforma a los individuos mediante [Aguilar, C and Rivas, F., 2001]:

- Evaluación de los Individuos.
- Selección de los padres.
- Cruce y mutación para crear hijos.
- Selección de los Sobrevivientes para la nueva generación.

El algoritmo evolutivo se detiene cuando se ha alcanzado algún criterio, por ejemplo, en la calidad de las soluciones obtenidas, en la cantidad de evaluaciones de la función objetivo o en el tiempo total de ejecución.

En resumen, para la implementación de un algoritmo evolutivo se deben contemplar los siguientes elementos:

- Una representación del espacio de soluciones.
- Un método para crear la población inicial.
- Una función de aptitud capaz de medir la calidad de cualquier individuo.
- Un método para seleccionar los padres y los sobrevivientes.

- Un conjunto de operadores genéticos.
- Un conjunto de parámetros que guían la evolución del algoritmo (tamaño de la población, número de iteraciones, probabilidades, etc).
- Un criterio de parada.

2.8.3. Ventajas y Desventajas.

Ventajas.

- (a). Incorporan el poder del cómputo actual para la reducción de problemas aún cuando se trata de espacios de búsqueda grandes.
- (b). No requieren conocimiento específicos sobre el problema que se intenta resolver.
- (c). No es necesario que el problema a resolver cumpla condiciones de continuidad o derivabilidad en sus funciones objetivo o restricciones ni que sean sencillas de evaluar en forma manual.
- (d). Operan sobre un conjunto de soluciones, lo que evita que la búsqueda se quede atascada en óptimos locales.
- (e). Se acoplan a la solución de problemas con objetivos múltiples, es decir, que no se resumen a un solo resultado, dado a que procesan simultáneamente a una población de individuos, los cuales representan soluciones a mejorar en cada iteración y al final del algoritmo se obtiene una buena aproximación de las soluciones que caracterizan al problema.
- (f). Pueden combinarse con otras técnicas de búsqueda para mejorar su desempeño.
- (g). Pueden explotar fácilmente las arquitecturas en paralelo, en caso de estar disponibles.

- (h). Generalmente pueden auto-adaptar sus parámetros.
- (i). Son capaces de resolver problemas para los cuales no se conoce solución alguna.
- (j). Son fáciles de implementar y usar.
- (k). Han tenido mucho éxito en aplicaciones reales.

Desventajas.

- (a). No existen reglas claras para ajustar los parámetros que controlan la dinámica del algoritmo, ni para decidir el tipo de operador que se debe utilizar.

2.9. ALGORITMOS EVOLUTIVOS MULTI-OBJETIVO (AEMO).

El potencial de los algoritmos evolutivos para resolver problemas de optimización multi-objetivo se remonta a finales de los 1960s, desde la tesis doctoral de Rosenberg, la cual indicó la posibilidad de usar algoritmos genéticos en este dominio. Sin embargo, el primer intento real por extender un algoritmo evolutivo a problemas multiobjetivo, es el trabajo desarrollado por J. David Schaffer. Su algoritmo, denominado *Vector Evaluated Genetic Algorithm (VEGA)* fue la entrada formal del cómputo evolutivo a la optimización multi-objetivo, a partir de ese momento muchos investigadores mostraron su interés en el desarrollo de este tipo de técnicas [Mezura, 2001].

Los algoritmos evolutivos multi-objetivo pueden clasificarse en dos grupos; los que utilizan directamente los conceptos de Pareto y los que no, siendo los primeros los de nuestro interés.

Elementos de los Algoritmos Evolutivos Multi-objetivo.

En esta sección se describen brevemente los elementos fundamentales de los algoritmos evolutivos multi-objetivo basados en el criterio de Pareto y se hace una descripción de los elementos que los conforman y que son característicos del enfoque de objetivos múltiples [Zitzler, E. et al., 2004].

Asignación de Aptitud.

Una de las diferencias más importante entre un algoritmo evolutivo simple y uno de objetivos múltiples es el esquema para asignar la aptitud a los individuos de la población. Mientras que en un AE se calcula un solo valor de aptitud en un AEMO se calculan varias funciones de aptitud.

El esquema para asignar la aptitud con base en la dominancia de Pareto consiste en marcar las soluciones que son no dominadas, asignarles una jerarquía más alta y retirarlos de la población. Este proceso continúa con las siguientes soluciones que son no dominadas y se les asigna otra jerarquía menos alta que la primera. Así, este proceso se realiza hasta que se ha asignado una jerarquía a cada individuo de la población.

Elitismo.

En procesos de optimización las buenas soluciones se pueden perder debido a los efectos de muestreo y a la disrupción de los operadores genéticos. Para resolver este problema, De Jong propuso un mecanismo llamado elitismo, el cual retiene a las mejores soluciones de la población de una generación a otra sin alteración. En los algoritmos evolutivos multi-objetivo, uno de los enfoque elitistas consiste en combinar la población vieja y la descendencia, y posteriormente aplicar una selección determinista en lugar de reemplazar

la población vieja por la descendencia.

Diversidad Poblacional.

En los algoritmos evolutivos multi-objetivo la meta es encontrar en una sola ejecución, un conjunto de soluciones bien distribuidas a lo largo del frente de Pareto, para lograr esto es importante conservar la diversidad de la población e incrementar la probabilidad de formar buenas soluciones. Esto se logra mediante la aplicación de técnicas como la aptitud compartida, que crea subpoblaciones de individuos (nichos) que comparten la aptitud o reemplazando los individuos viejos por los individuos nuevos mas similares.

Capítulo 3

MARCO METODOLÓGICO

En este capítulo se detallan las técnicas utilizadas en el desarrollo de esta investigación.

3.1. MODELADO DE POZOS.

Una vez estudiado el proceso de producción de petróleo con levantamiento artificial por gas y establecidas las bases teóricas necesarias, se desarrollaron un conjunto de algoritmos para dar solución al problema planteado, utilizando el lenguaje matemático MATLAB en su versión R2008b, como restricción técnica indicada por los líderes del proyecto de Optimización de la Producción Basada en Computación Inteligente, dada la versatilidad, robustez y fácil manejo que proporciona dicha plataforma.

En esta etapa de la investigación, fue de relevante importancia la determinación de las variables de producción que afectan el proceso y que son de carácter dinámico.

Las Variables de producción se clasifican según su estado en el tiempo en variables de carácter dinámico y variables de carácter estático, así como también según su ubicación en el sistema se clasifican en variables de subsuelo, fluido y superficie.

En la tabla 3.1 se clasifican las principales variables involucradas en el sistema pozo - yacimiento:

Tabla 3.1: Variables del Sistema Pozo - Yacimiento. Tomado de [Charrouf, 2001]

Variable	Ubicación en el Sistema	Carácter
<i>Presión de Yacimiento</i>	Subsuelo	Estático
<i>Presión de Fondo Fluyente</i>	Subsuelo	Estático
<i>Relación Gas Petróleo</i>	Fluido	Dinámico
<i>Porcentaje de Agua y Sedimentos</i>	Fluido	Dinámico
<i>Caudal de Líquido</i>	Fluido	Dinámico
<i>Caudal de Inyección de Gas</i>	Subsuelo	Dinámico
<i>Presión de Cabezal</i>	Superficie	Estático
<i>Presión de Separación</i>	Superficie	Estático
<i>Diámetros de Tuberías y Válvulas</i>	Subsuelo-Superficie	Estático
<i>Gravedad API del Fluido</i>	Fluido	Estático
<i>Profundidad de las Perforaciones</i>	Subsuelo	Estático
<i>Profundidad de las Válvulas de Inyección</i>	Subsuelo	Estático
<i>Longitud de Líneas de Producción</i>	Superficie	Estático
<i>Presión de Inyección de Gas Presurizado</i>	Subsuelo	Dinámico
<i>Saturación del Gas en el Petróleo</i>	Fluido	Estático
<i>Presión de Burbujeo</i>	Fluido	Estático

Como se aprecia en la tabla 3.1 la mayoría de las variables del sistema son de carácter estático. Entre las variables dinámicas, el Porcentaje de Agua y Sedimentos y la Relación Gas Petróleo que son propiedades del fluido, varían en una proporción muy pequeña a través del tiempo, lo que las hace poco representativas para el sistema. Por otro lado la tasa de inyección de gas es una variable de principal interés para el modelo y se toma como entrada al sistema. La presión de inyección de gas aún cuando es de carácter dinámico está estrechamente vinculada con el volumen de inyección y la finalidad es mantenerla estable, debido a ello no se tomó en cuenta como entrada al sistema.

El caudal de líquido corresponde a la cantidad de crudo y agua que se logra extraer mediante el proceso de inyección. La tasa de producción de crudo por pozo, es el resultado de la resta entre el caudal de crudo y la cantidad de agua producida y se seleccionó como

variable de salida del sistema.

Otro aspecto importante es la Curva de Rendimiento del Pozo. Para construir la curva de comportamiento de un pozo se necesita una variación de la tasa de inyección y la tasa de producción asociada. Conseguir la data necesaria para llevar a cabo esa operación resulta altamente costoso ya que se tendría que experimentar con cada uno de los pozos por cierto periodo de tiempo, lo cual no sería posible ni rentable.

Los datos para realizar elaborar estas curvas son generados por simuladores petroleros que estiman el comportamiento del pozo bajo condiciones de simulación, es decir, reproducen el comportamiento del pozo en determinado momento tomando en cuenta todas las variables del pozo y el yacimiento para ese momento.

A partir de los modelos de pozos construidos por los simuladores de producción se generó un modelo neuronal sustituto simplificado que depende exclusivamente de las variables de entrada y salida seleccionadas y que permite emular el comportamiento de la producción de los pozos cuando estas variables cambien.

Los datos generados por los simuladores petroleros representan de manera significativa el comportamiento producción/inyección del sistema de levantamiento artificial por gas en condiciones reales. Las válvulas de inyección de gas se encuentran calibradas para permitir intervalos máximos de inyección, es decir, que el operador de producción puede inyectar ciertas cantidades de gas a alta presión en intervalos de tiempos permitidos para no causar daños a las instalaciones o pérdidas de recursos. Este comportamiento físico dio pie a una ordenación de las variables de entrada - salida del modelo que se aproxima más al sistema real.

En este sentido, se incorporó retraso a las variables representativas del sistema para redefinir el conjunto de entrada - salida del modelo.

En este tipo de estructura, las variables están retrasadas con respecto al instante en que se efectúa la medición, y se define formalmente de la siguiente manera:

$$\hat{y}(t) = f[x(t), x(t-1), x(t-2), \dots, x(t-nA+1), \dots, y(t-1), \dots, y(t-nB+1)] \quad (3.1)$$

Donde nA es la cantidad de veces que se retrasa la señal de entrada y nB la cantidad de veces que se retrasa la señal de salida. De forma general nA es mayor que nB y el número total de variables de entrada es $nA + nB$, pero estos parámetros son ajustables. La figura 3.1 describe este procedimiento:

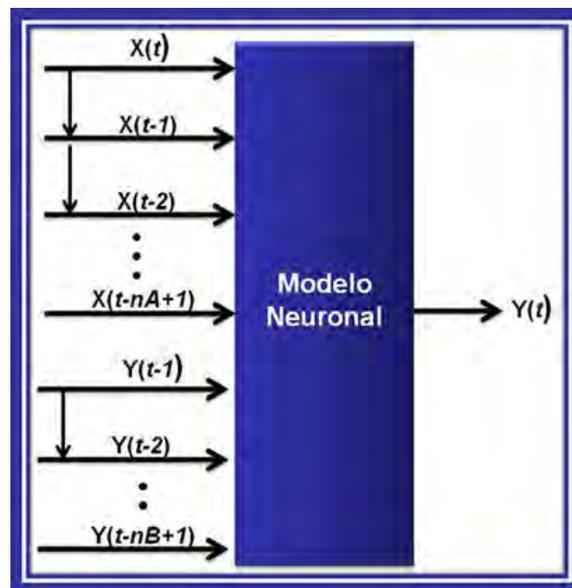


Figura 3.1: Modelo de Regresores de Entrada - Salida.

Una vez definidas las variables de entrada y salida del modelo se realizó un estudio exhaustivo de los diferentes tipos de Redes Neuronales para determinar el tipo de red a utilizar. Dadas las características de los datos, se consideraron las Redes Multicapa, ya que ellas ajustan sus pesos en el proceso de aprendizaje y luego estos quedan fijos, además el tipo de aprendizaje requerido es el aprendizaje supervisado, es decir, para un conjunto de datos de entrada se presenta un conjunto de salida.

Luego de diferentes simulaciones se obtuvo que una Red Multicapa con diez neuronas en la capa de entrada y quince neuronas en la capa de procesamiento o capa escondida.

Las redes para los pozos son entrenadas con el algoritmo de Levenberg - Marquardt, debido a que ofrece mejor tiempo de convergencia para el entrenamiento en comparación con métodos como el descenso del gradiente y el descenso del gradiente con momento.

3.2. MODELO DE OPTIMIZACIÓN MULTI-OBJETIVO.

Como se mencionó en la sección anterior, para cada pozo se tiene un total de cuatro variables de entrada y una variable de salida, en este sentido, se define un vector de entradas $Z_i(k)$ de la forma:

$$Z_i(k) = [x_i(k), x_i(k-1), x_i(k-2), y_i(k-1)]^T, \text{ para } i = 1, \dots, 21 \text{ pozos.} \quad (3.2)$$

Donde $x_i(k)$, $x_i(k-1)$, $x_i(k-2)$, corresponden a las tasas de inyección con dos retardos y $y_i(k-1)$ un retraso en la tasa de producción de crudo del pozo i .

La salida del sistema está definida por la tasa de producción de crudo en el instante de medición k , $Y_i(k)$ del pozo i , para $i = 1, \dots, 21$.

Se estableció el **Error de la Producción** (Ep_i) como la diferencia entre lo que el pozo i está produciendo en la actualidad ($Y_i(k)$) y su correspondiente salida neuronal (Yn_i), esto se representa mediante la siguiente expresión:

$$Ep_i = y_i(k) - Yn_i \quad (3.3)$$

En base al error en la producción (E_p) se definió el *Índice de Productividad* del pozo i de la siguiente manera:

$$J_i = \frac{1}{2} (E_i Q_{i,i} E_i^T), \text{ para } i = 1, \dots, 21. \quad (3.4)$$

Donde Q es una matriz diagonal, que penaliza los pozos en atención a un criterio establecido. Contiene valores que determinan la importancia de cada pozo en el sistema, por ejemplo, los pozos que están cercanos a las plantas compresoras y son buenos productores tienen prioridad, por lo que se le asignan altos valores de Q . Por otro lado, a los pozos que están alejados de la planta compresora y no son buenos productores se les asigna un valor de Q menor. La matriz Q es un parámetro ajustable y puede ser refinado en base a la experiencia y los requerimientos de los ingenieros de producción.

En este orden de ideas y tomando en cuenta que el gas disponible para inyección tiene un valor máximo de disponibilidad y que la tasa de producción promedio de la estación de flujo en estudio tiene un valor mínimo permitido, la definición formal del modelo de optimización es la siguiente:

Maximizar J_i en el espacio $Z_i(k)$

Sujeto a:

$$\sum_{i=1}^{21} x_i(k) \leq x_{\text{máx}} \text{ Restricción sobre el gas de alta disponible.} \quad (3.5)$$

$$\sum_{i=1}^{21} y_i(k) \geq y_{\text{mín}} \text{ Restricción sobre la producción mínima.} \quad (3.6)$$

Donde $x_{\text{máx}}$ corresponde a la cantidad máxima de gas de la que se dispone para inyección y $y_{\text{mín}}$ la producción mínima permitida para esa unidad de explotación.

La ecuación 3.1 puede ser expresada de la forma:

$$J = [J_1, J_2, J_3, \dots, J_{21}] \quad (3.7)$$

$$J = \frac{1}{2} \left(E_1^2(k) Q_{1,1} + E_2^2(k) Q_{2,2} + \dots + E_{21}^2(k) Q_{21,21} \right) \quad (3.8)$$

De las ecuaciones 3.2 y 3.3 y definiendo $E_r(k) = [E_1(k), E_2(k), E_3(k), \dots, E_{21}(k)]$ y $Z_r(k) = [z_1(k), z_2(k), z_3(k), \dots, z_{21}(k)]$ decimos que el problema de optimización se puede escribir de la forma:

Maximizar J en el espacio $Z_t(k)$

Sujeto a:

$$\sum_{i=1}^{21} x_i(k) \leq x_{\text{máx}}$$

$$\sum_{i=1}^{21} y_i(k) \geq y_{\text{mín}}$$

Para dar solución a este problema de optimización se plantea aplicar un algoritmo algoritmo multi-objetivo, el cual es descrito en la siguiente sección.

3.3. ALGORITMO EVOLUTIVO MULTI-OBJETIVO.

El algoritmo multi-objetivo propuesto es una adaptación del algoritmo “*Non-dominated Sorting Genetic Algorithm (NSGA-II)*” propuesta por Srinivas y Deb en 1994 [?]. Se basa en clasificar a la población en niveles o capas de dominación asignándoles jerarquías, mediante el ordenamiento no dominado y calculando las distancias entre individuos para preservar la diversidad a través de la distancia de agrupamiento.

3.3.1. Representación de los Individuos.

Este parámetro es de gran importancia ya que permite definir el espacio de las variables de decisión donde se moverán los algoritmos de optimización para encontrar el conjunto de soluciones factibles. En esta investigación se prefiere una representación de los individuos en números reales ante una representación binaria, dado a que facilita la inicialización de la población y la acerca más a la realidad, además de que su implementación es más sencilla que la codificación binaria.

En este enfoque multi-objetivo se define una estructura de individuo sencilla, unidimensional, que es un vector fila cuyo número de columnas corresponde al número de entradas que tiene el sistema, como se muestra en la ecuación 3.2, $Z_i(k) = [x_i(k), x_i(k - 1), x_i(k - 2), y_i(k - 1)]$. Para crear la población inicial se genera un conjunto de individuos con esta estructura para cada pozo, donde el tamaño total de la población debe tener como mínimo 22 individuos, es decir, se tendrán grupos de individuos donde cada nicho representa un pozo en particular.

3.3.2. Ordenamiento No Dominado.

En este parámetro los individuos son jerarquizados de acuerdo a su pertenencia o cercanía a la frontera de Pareto. Si un individuo pertenece al frente de Pareto se le asigna un rango igual a 1. Para determinar qué individuos pertenecen a las siguientes capas, se eliminan los individuos de la primera capa de la población y se vuelven a determinar las soluciones no dominadas, a las cuales se les asigna un rango igual a dos y así sucesivamente con los individuos restantes de la población.

Este enfoque se conoce como *ordenamiento rápido no dominado* [Deb, K. et al., 2002], en el cual para cada individuo p de la población P se determina el valor de dos entidades:

1. Un contador de dominación n_p , que indica el número de soluciones que domina la solución p .
2. Un conjunto de soluciones S_p que la solución p domina.

Todas las soluciones en el primer frente no dominado (F_1), tendrán su contador de dominancia n_p igual a cero puesto que ninguna solución las domina. Por cada solución p con $n_p = 0$, se visita cada miembro q del conjunto S_p y se decrementa su contador en uno.

Al hacerlo, si para algún miembro q el contador de dominación llega a ser cero, este punto se agrega a una lista L .

Todos los miembros de L pertenecen al segundo frente no dominado (F_2). Se continúa con el procedimiento anterior con cada miembro de L y se forma el tercer frente no dominado (F_3). Este procedimiento se mantiene, hasta que todos los frentes (F_i) son identificados. El pseudo-código del algoritmo de ordenamiento no dominado (non - dominated sort) se muestra a continuación:

1. Inicio.

2. Repetir para cada individuo p de la población principal P .

2.1 Se inicializa $S_p = \emptyset$; ese conjunto contiene todos los individuos que son dominados por p .

2.2 Se inicializa $n_p = 0$. Este sería el número de individuos que dominan a p .

2.3 Repetir para cada individuo q en P

2.3.1 Si p domina a q entonces

2.3.1.1 Se agrega q al conjunto S_p . $S_p = S_p \cup \{q\}$.

2.3.2 Sino, si q domina a p entonces

2.3.2.1 Se incrementa el contador de dominancia para p . $n_p = n_p + 1$.

2.3.3 Fin Si.

2.4 Fin del Repita Para.

2.5 Si $n_p = 0$ ningún individuo domina a p entonces

2.5.1 p pertenece al primer frente y se le asigna el rango 1 $p_{rank} = 1$.

2.5.2 Se actualiza el primer frente añadiendo p al conjunto $F_1 = F_1 \cup \{p\}$

3. Inicializo el contador de frente en 1. $i = 1$.

4. *Fin de Repita Para.*

5. *Repetir mientras el i -ésimo frente no esté vacío $F_i \neq \emptyset$.*

5.1 *$L \neq \emptyset$ El conjunto para almacenar los individuos para el $(i + 1)^{th}$ frente.*

5.2 *Repetir para cada individuo p en el frente F_i*

5.2.1 *Repetir para cada individuo q en S_p . (S_p es el conjunto de los individuos dominados por p).*

5.2.1.1 *$n_q = n_q - 1$, se decrementa el contador de dominación para el individuo q .*

5.2.1.2 *Si $n_q = 0$ ninguno de los individuos en los frentes siguientes dominaran a q , entonces.*

■ *El conjunto $q_{rank} = i + 1$.*

■ *Se actualiza el conjunto L con el individuo q . $L = L \cup q$.*

5.2.1.3 *Fin del Repita Para.*

5.2.2 *Fin del Repita Para.*

5.3 *Fin del Repita Para.*

5.4 *Se incrementa el contador de Frente en uno.*

5.5 *Ahora el conjunto L es el próximo frente y por lo tanto $F_i = L$.*

6. *Fin de Repita Mientras.*

7. *Fin.*

3.3.3. Distancia de Agrupamiento (Crowding Distance).

Una vez que el ordenamiento no dominado está completo, se asigna la distancia de agrupamiento. La idea principal de este parámetro es encontrar la distancia que existe entre un

individuo y sus vecinos más cercanos. Los individuos en los límites siempre son seleccionados desde que se les asigna distancia de agrupamiento infinita. (∞). Un alto promedio de distancia de agrupamiento significa mejor diversidad en la población [Deb, K. et al., 2002].

El algoritmo de distancia de agrupamiento se describe a continuación:

1. *Inicio.*

2. *Repetir para cada frente F_i , sea n el número de individuos.*

2.1 *Se inicializa la distancia en cero para todos los individuos. $F_i(d_j) = 0$, donde j corresponde al j^{th} individuo en el frente.*

2.2 *Repetir para cada función objetivo m*

2.2.1 *Se ordenan los individuos en el frente F_i en base a sus objetivos m . $I = \text{sort}(F_i, m)$.*

2.2.2 *Se le asigna el valor de infinito ∞ , al valor de la distancia de agrupamiento para cada individuo perteneciente a los límites. $I(d_1) = \infty, I(d_n) = \infty$.*

2.2.3 *Para cada $k = 2$ hasta $(n - 1)$.*

$$\blacksquare I(d_k) = I(d_k) + \frac{I(k+1).m - I(k-1).m}{f_m^{\text{máx}} - f_m^{\text{mín}}}.$$

■ $I(k).m$, es el valor de la m^{th} ésima función objetivo del k^{th} ésimo individuo en I .

2.2.4 *Fin del Repita Para.*

2.3 *Fin del Repita Para.*

3. *Fin.*

3.3.4. Operador de comparación de agrupamiento (crowded-comparison-operator).

El operador de comparación de agrupamiento $<_n$, guía el proceso de selección a varias fases del algoritmo hacia un frente de Pareto óptimo y disperso. Asumiendo que cada individuo i en la población tiene dos atributos:

Una vez que los individuos son ordenados basados en el principio de no-dominancia y con una distancia de agrupamiento asignada, la selección se lleva a cabo utilizando el operador de agrupamiento y comparación (crowded - comparison- operador) ($<_n$) que se encarga de guiar el proceso de selección a varias fases del algoritmo hacia un frente de Pareto óptimo y disperso [Deb, K. et al., 2002]. Asumiendo que cada individuo i en la población tiene dos atributos:

- i. Jerarquía de no dominación i_{rank} .
- ii. Distancia de agrupamiento i_{dist} .

Se define un orden parcial $<_n$ como:

$$i <_n j \begin{cases} \text{if}(i_{rank} < j_{rank}) \\ \text{or}((i_{rank} = j_{rank}) \text{and}(i_{dist} > j_{dist})) \end{cases}$$

Lo anterior significa, que entre dos soluciones con distintos rangos de no dominación, se prefiere la solución con el menor rango. En otro caso, si dos soluciones pertenecen al mismo frente, entonces se prefiere la solución que está ubicada en una región de menor densidad.

En esta técnica se introduce el concepto de elitismo al compara la población actual con las mejores soluciones previamente encontradas.

3.3.5. Operadores Evolutivos.

Se definieron operadores de cruce y mutación acordes a la representación de los individuos definida.

Operador de Cruce.

Como se trata de una representación real de los individuos, se utilizó el método *Simulated Binary Crossover (SBX)*, propuesto por [Deb, K. and Agrawal, R., 1994], que intenta emular el cruce de un punto usada con representación binaria. El algoritmo es el siguiente:

1. Generar un número aleatorio “ u ” entre 0 y 1.
2. Calcular $\bar{\beta}$:

$$\bar{\beta} = \begin{cases} (2u)^{\frac{1}{n_c+1}} & \text{Si } u \leq 0,5 \\ \left(\frac{1}{2(1-u)}\right)^{\frac{1}{n_c+1}} & \text{en caso contrario.} \end{cases} \quad (3.9)$$

Donde $n_c = 0$ ó 1 . El operador de cruce aplicado a los individuos con la estructura definida en las sección 3.3.1 se aplica respetando las poblaciones de pozos independientes, es decir, los nichos de pozos. Una vez seleccionados los progenitores en base a al ordenamiento no dominado y la distancia de agrupamiento, se aplica el operador de cruce a cada uno y se genera la descendencia.

Operador de Mutación.

Como operador de mutación se utilizó el método *Parameter-Based Mutation (PBM)* propuesto por [Deb, K. and Agrawal, R., 1994], cuyo procedimiento es el siguiente:

1. Generar un número aleatorio “ u ” entre 0 y 1.
2. Calcular $\bar{\delta}$:

$$\bar{\delta} = \begin{cases} (2u)^{\frac{1}{n_m+1}} & \text{Si } u \leq 0,5 \\ \text{ValorMáximo en caso contrario} & \end{cases} \quad (3.10)$$

Donde n_m es el índice de distribución para la mutación y toma cualquier valor no negativo. Deb sugiere usar $n_m = 100 + t$ $t = \text{Generación Actual}$.

3.3.6. Ciclo del Algoritmo Evolutivo Multi-objetivo propuesto.

El ciclo completo del NSGA-II se ve reflejado en el siguiente pseudo-código y en el diagrama de flujo mostrado en la figura 3.2:

Entradas:

- *Tamaño de la población.*
- *Número máximo de generaciones.*
- *Espacio de Búsqueda.*
- *Probabilidad de Cruce.*
- *Probabilidad de Mutación.*

Salidas:

- *Conjunto de Pareto óptimo encontrado.*

- *Valores finales de las funciones objetivo.*

1. *Inicio*

2. *Inicializar la población P_t de acuerdo a la estructura mostrada en la ecuación 3.2.*

3. *Evaluar la población P_t de acuerdo a sus funciones objetivo.*

4. *Asignar jerarquía con base a la dominancia de Pareto en cada frente.*

5. *Obtener el número del contador del nicho (pozo).*

6. *Asignar el valor de aptitud compartida.*

7. *Repetir para $i = 0$ hasta el máximo de generaciones.*

7.1 *Selección, cruce y mutación para generar una nueva población L_t .*

7.2 *Evaluar la población L_t de acuerdo a las funciones objetivo.*

7.3 *Aplicar el principio de elitismo para sustituir la población $R_t = P_t \cup L_t$ y asignar Jerarquía con base a la dominancia de Pareto a R_t .*

7.4 *Obtener el número de contador de nicho (pozo).*

7.5 *Asignar el valor de aptitud mediante el operador de comparación.*

7.6 *Seleccionar los N individuos de R_t , de acuerdo al operador de comparación de agrupamiento para obtener P_{t+1} .*

8. *Fin Repita Para.*

9. *Fin.*

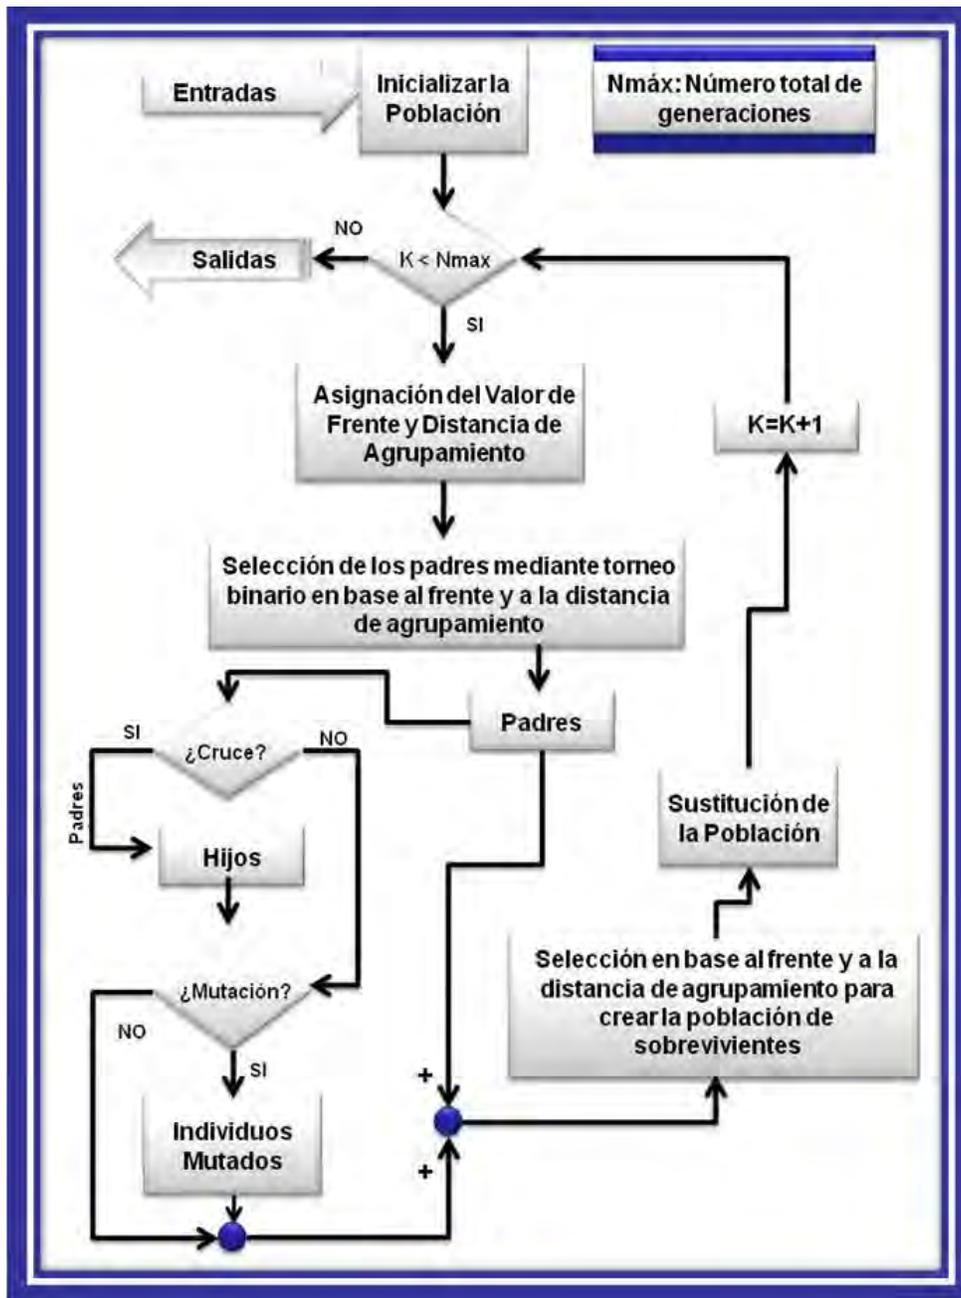


Figura 3.2: Diagrama de Flujo del Algoritmo Evolutivo Multi-objetivo (NSGA-2)

Capítulo 4

RESULTADOS Y DISCUSIÓN

En este capítulo se muestran los resultados de las pruebas realizadas para la validación del modelo de optimización propuesto y los resultados de la optimización. Se utilizaron datos de mediciones provenientes de la Estación de Flujo 1-12 de la Unidad de Explotación LAGOMAR de PDVSA, que está formada por 21 pozos asistidos mediante Levantamiento Artificial por Gas (LAG).

4.1. RESULTADOS DEL MODELADO DE POZOS.

La identificación de los modelos de los pozos con Redes Neuronales Multicapa, constituye un paso de relevancia para la operación del modelo de optimización. Los resultados obtenidos con los modelos neuronales aproximan, con una tolerancia aceptable, al comportamiento de los datos medidos de los pozos. La obtención de los modelos de comportamiento de la producción de los diferentes pozos es uno de los objetivos previstos en este trabajo.

Para propósitos de la construcción de los modelos neuronales, el programa realizado

lee los archivos de texto plano que contienen la data de los pozos y los separa en dos grupos. Se tomó un 40 % para data de entrenamiento y el complemento para validación. Adicionalmente se fijaron los parámetros para el entrenamiento. Se estipuló una tasa de aprendizaje de 0,01, un máximo de 100 épocas y un error cuadrático medio máximo de 10×10^{-2} , como criterios de parada.

En la Tabla 4.1 se presentan los resultados del error final en entrenamiento y coeficiente de correlación calculados para los datos de validación de cada uno de los pozos modelados. Estos valores permiten ver el grado de generalización de las Redes Neuronales Multicapa usadas en la aplicación.

Tabla 4.1: Resultados de Entrenamiento y Validación de los Modelos Neuronales.

Número	Pozo	Coefficiente de Correlación	Error Cuadrático Medio	Error Porcentual
1	LLB0018	0,9945	0,0666	2,4444
2	LLB0021	0,9928	0,0852	2,4539
3	LLB0022	0,9960	0,0678	2,1895
4	LLB0026	0,9827	0,0659	2,1577
5	LLB0042	0,9972	0,0333	1,5334
6	LLB0047	0,9855	0,0750	2,3025
7	LLB0050	0,9966	0,0246	1,3179
8	LLB0051	0,9913	0,0182	1,0989
9	LLB0052	0,9950	0,0455	1,7939
10	LLB0053	0,9933	0,0821	2,4089
11	LLB0059	0,9556	0,0031	0,4547
12	LLB0060	0,9961	0,0521	1,9898
13	LLB0061	0,9702	0,0023	0,3879
14	LLB0062	0,9761	0,0053	0,5933
15	LLB0063	0,9885	0,0487	1,8559
16	LLB0064	0,9940	0,0335	1,5385
17	LLB0065	0,9816	0,0914	2,5411
18	LLB0066	0,9868	0,0524	1,9965
19	LLB0067	0,9759	0,0056	0,6126
20	LLB0069	0,9619	0,0731	2,2032
21	LLB0070	0,9951	0,0463	1,8092
	PROMEDIO	0,9731	0,0445	1,6245

En general, para los 21 pozos seleccionados, se obtuvo un promedio del error porcentual del 1.62 %. En promedio el error cuadrático fue de 0,0445 y el coeficiente de correlación promedio de 0.9731.

Modelos Neuronales Obtenidos.

A continuación se muestran los modelos neuronales que representan en gran medida el comportamiento de los pozos en estudio. Los modelos neuronales fueron creados utilizando la caja de herramientas de MATLAB para redes neuronales.

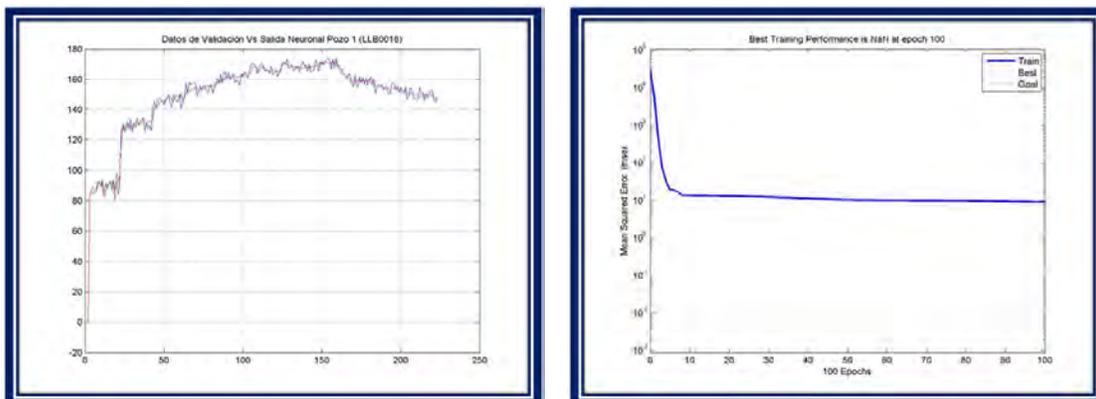
Pozo 1 (LLB0018).

La figura 4.1 muestra el modelo neuronal del pozo 1 (LLB0018). Se observa que la curva crece hasta alcanzar un máximo de producción entre los 160 y los 180 BNPD con una tasa de inyección de gas que entre los 1200 y los 1400 MPCND, luego decrece para tasas de inyección superiores.

El modelo obtenido representa con un error porcentual del 2,44 % el comportamiento real del pozo 1, como se observa en la figura 4.2(a), la cual muestra una superposición de los datos reales seleccionados para validación y la curva de comportamiento del pozo. Por otro lado, En la figura 4.2(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 1, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.



Figura 4.1: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 1 (LLB0018)



(a) BN(k) (rojo) Vs BNn(k) (azul) del pozo 1 (LLB0018)

(b) ECM Vs. Épocas, pozo 1 (LLB0018)

Figura 4.2: Modelado Neuronal del Pozo 1 (LLB0018)

Pozo 2 (LLB0021).

El pozo 2 (LLB0021) tiene un comportamiento como el que se muestra en la figura 4.3. La curva crece hasta alcanzar un valor máximo superior a los 160 BNPD, para una tasa de inyección que se acerca a los 800 MPCND, luego los valores de producción decrecen para tasas de inyección superiores.

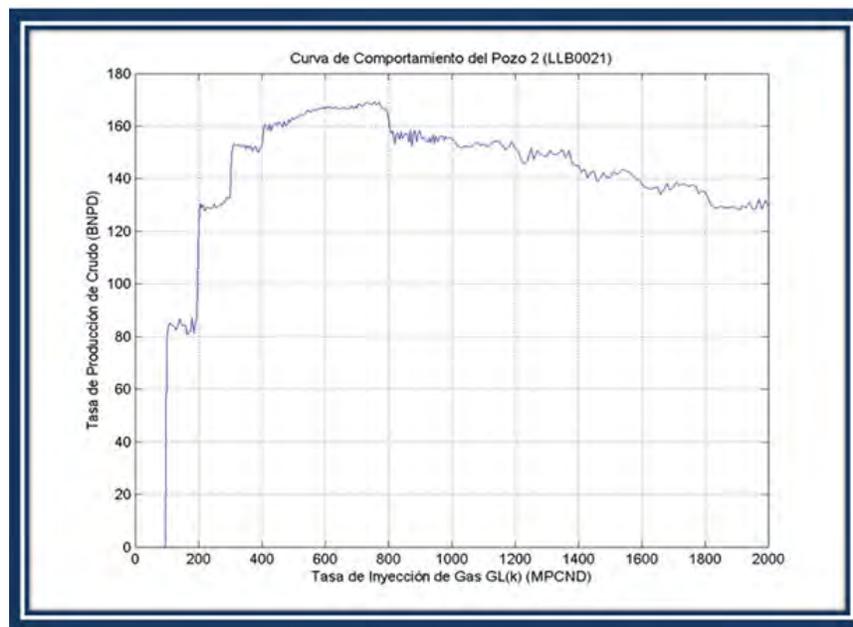
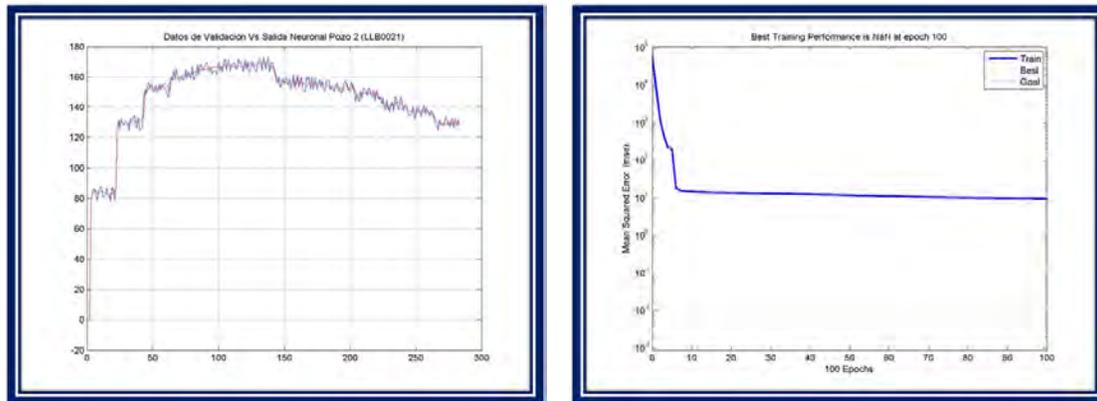


Figura 4.3: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 2 (LLB0021)

En la figura 4.4(a) se observa que el modelo obtenido se acerca con un error porcentual del 2,45 % a los datos reales seleccionados para la validación del modelo neuronal del pozo 2. En la figura 4.4(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 2, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 2 (LLB0021)

(b) ECM Vs. Épocas, pozo 2 (LLB0021)

Figura 4.4: Modelado Neuronal del Pozo 2 (LLB0021)

Pozo 3 (LLB0022).

En la figura 4.5 se observa que el pozo 3 (LLB0022) presenta un comportamiento creciente hasta aproximadamente unos 500 MPCND, a partir de ese punto comienza una porción de la gráfica cercana a los 250 BNPD en donde se podría encontrar el máximo de la producción, acercándose a los datos reales con un error porcentual del 2,19 %. Para tasas de inyección superiores a los 850 MPCND la tasa de producción decrece un poco y luego permanece en valores que se acercan a los 200 BNPD.

En la figura 4.6(a) se observa el mismo comportamiento descrito en la figura 4.5 y como se ajusta eficientemente a los datos reales seleccionados para la validación del modelo. Por otra parte, en la figura 4.6(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 3, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

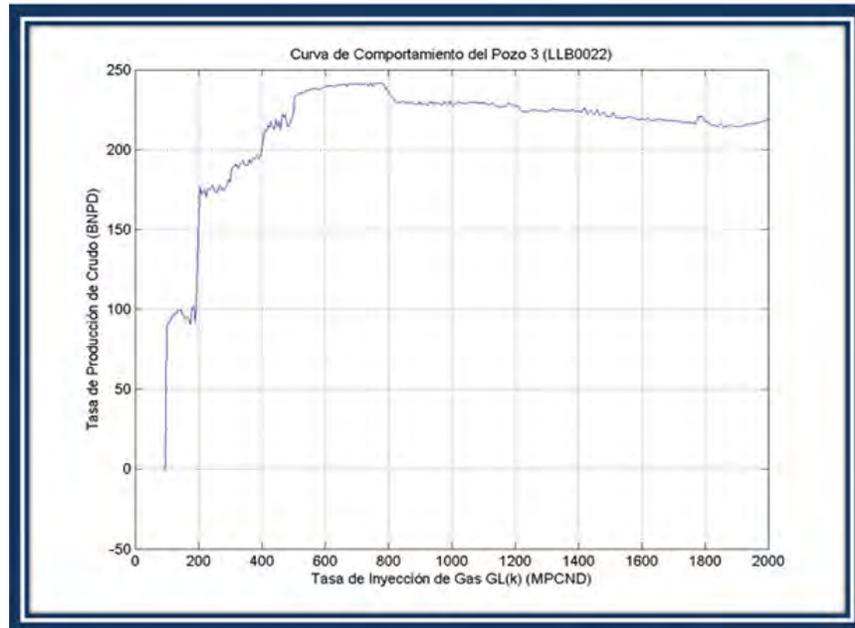
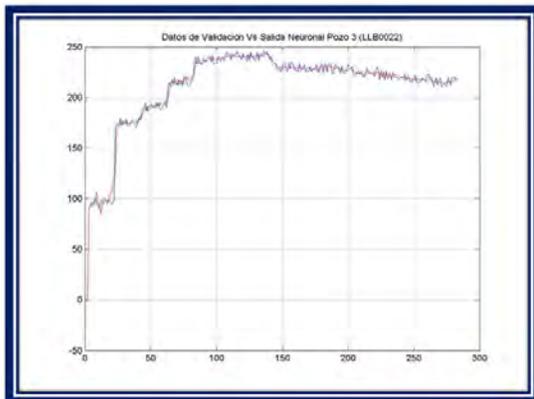
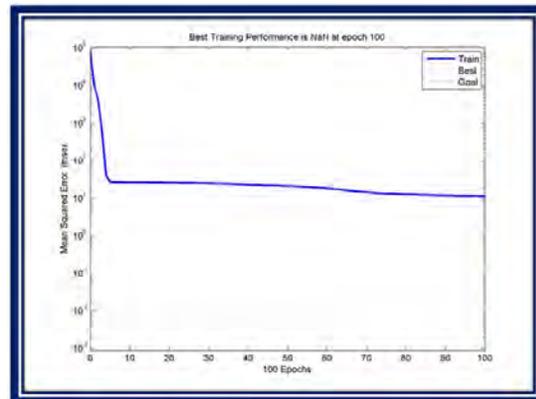


Figura 4.5: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 3 (LLB0022)



(a) BN(k) Vs BNN(k) del pozo 3 (LLB0022)



(b) ECM Vs. Épocas, pozo 3 (LLB0022)

Figura 4.6: Modelado Neuronal del Pozo 3 (LLB0022)

Pozo 4 (LLB0026).

La curva de comportamiento del pozo 4 (LLB0026) se ve representada mediante la figura 4.7, se observa que la tasa de producción crece para inyecciones cercanas a los 400 MPCND, hasta que la producción neta alcanza valores muy cercanos a los 80 BNPD, sección en la cual se puede encontrar el óptimo de la producción. Este comportamiento se mantiene hasta tasas de inyección cercanas a los 1000 MPCND donde comienza a decrecer, el modelo se aproxima a los datos reales con un error porcentual del 2,16 %.

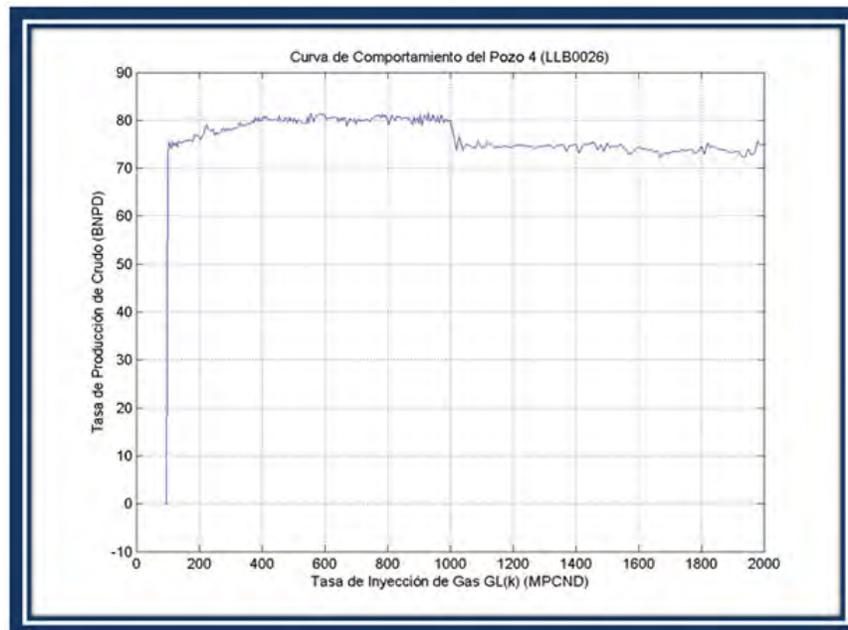
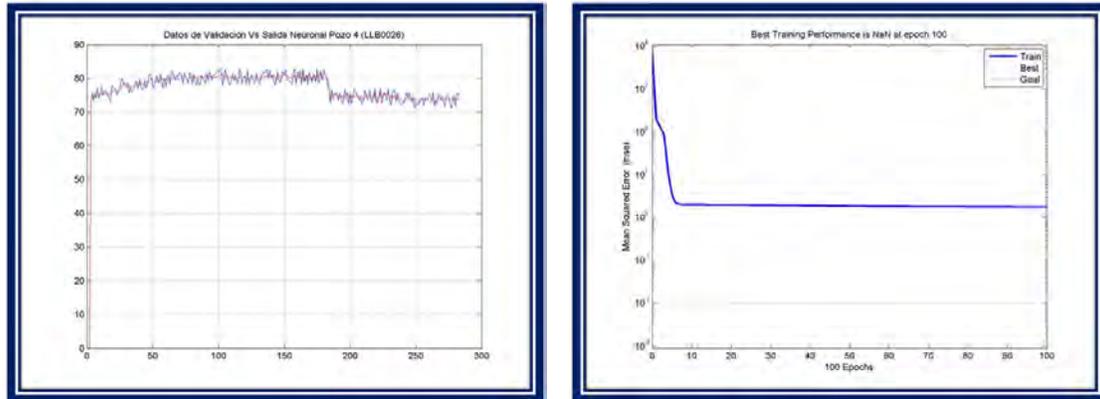


Figura 4.7: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 4 (LLB0026)

En la figura 4.8(a) se superponen el comportamiento del pozo con la muestra de datos seleccionados para la validación del modelo neuronal los cuales coinciden eficientemente. En la figura 4.8(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 4, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 4 (LLB0026)

(b) ECM Vs. Épocas, pozo 4 (LLB0026)

Figura 4.8: Modelado Neuronal del Pozo 4 (LLB0026)

Pozo 5 (LLB0042).

El comportamiento del pozo 5 (LLB0042) se ve reflejado en la figura 4.9 la cual muestra un comportamiento creciente hasta alcanzar valores cercanos los 600 MPCND de gas de inyección, a partir de ese punto hay una pequeña porción de curva donde puede estar el óptimo de la producción y luego el comportamiento es decreciente, el modelo se acerca a los datos reales con un error porcentual del 1,53 %.

En la figura 4.10(a) se ve representado el mismo comportamiento superpuesto con la data seleccionada para la validación del modelo y se observa que hay una correspondencia aceptable entre ambos. En la figura 4.10(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 5, el cual decrece rápidamente hasta 20 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

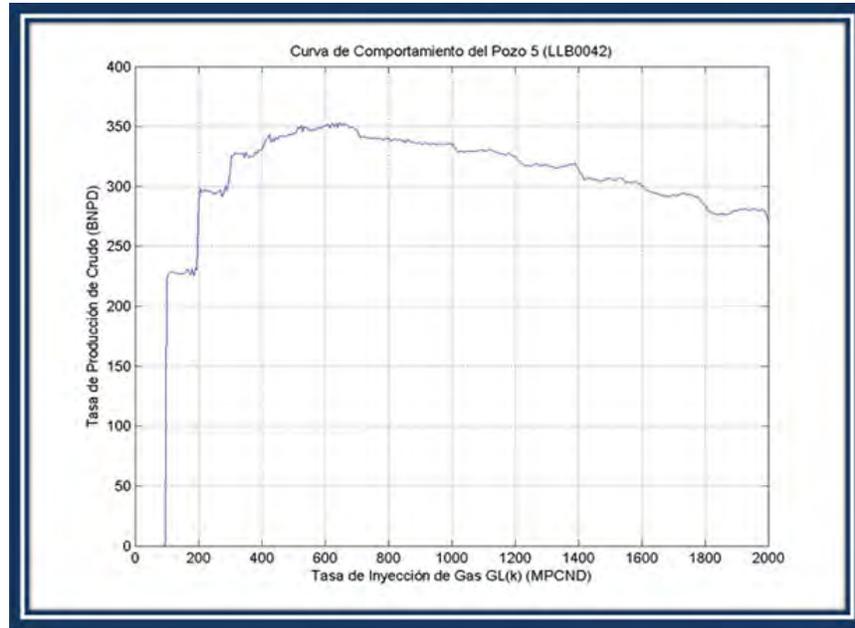
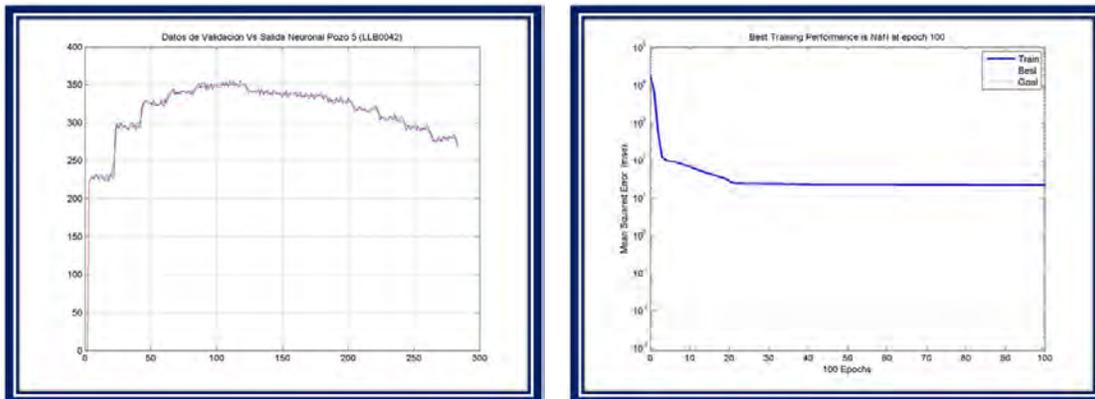


Figura 4.9: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 5 (LLB0042)



(a) BN(k) Vs BNN(k) del pozo 5 (LLB0042)

(b) ECM Vs. Épocas, pozo 5 (LLB0042)

Figura 4.10: Modelado Neuronal del Pozo 5 (LLB0042)

Pozo 6 (LLB0048).

En la figura 4.11 se observa que la tasa de de producción del pozo 6 (LLB0048) crece rápidamente hasta alcanzar un valor máximo, esto ocurre para valores bajos de inyección. Para una tasa de inyección entre los 400 y 600 MPCND se encuentra el valor máximo de la producción neta para este pozo que puede estar cerca de los 140 BNPD, el modelo se aproxima a los datos reales con un error porcentual del 2,30 %.

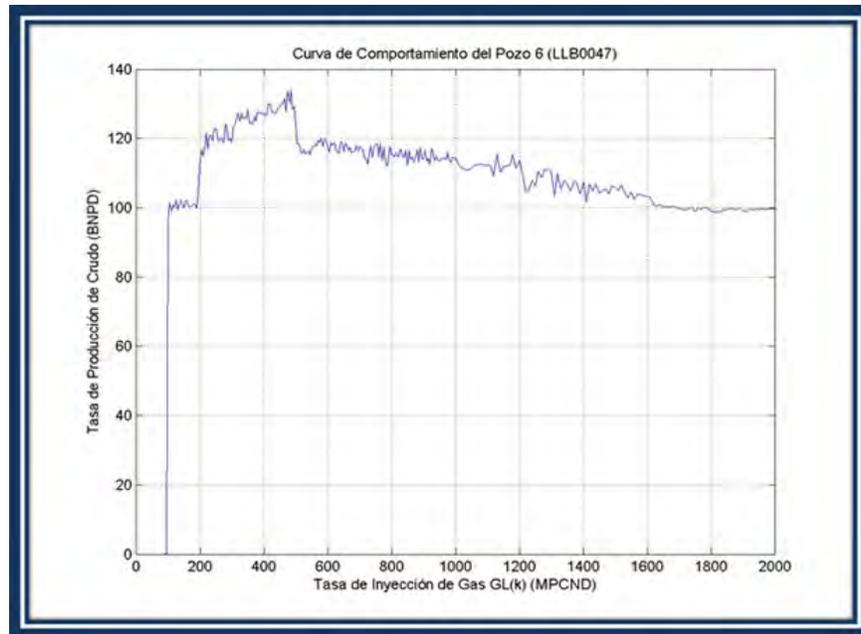
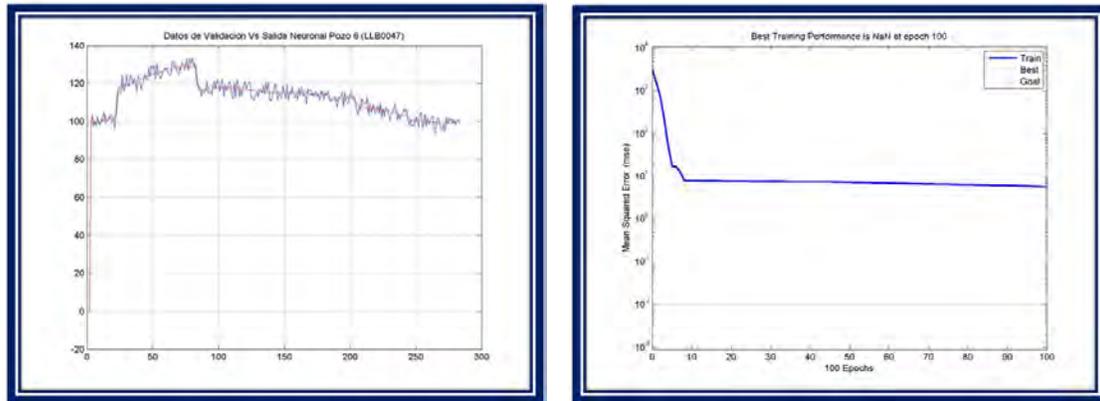


Figura 4.11: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 6 (LLB0047)

La figura 4.12(a) muestra que el modelo neuronal del comportamiento del pozo se ajusta a los datos utilizados para la validación. En la figura 4.12(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 6, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.



(a) BN(k) Vs BNn(k) del pozo 6 (LLB0047)

(b) ECM Vs. Épocas, pozo 6 (LLB0047)

Figura 4.12: Modelado Neuronal del Pozo 6 (LLB0047)

Pozo 7 (LLB0050).

La figura 4.13 representa el modelo neuronal que simula el comportamiento del pozo 7 (LLB0050), el cual se aproxima a los datos reales con un error porcentual del 1,32 %. Se observa que para valores bajos de inyección hasta alcanzar los 800 MPCND la curva es creciente para luego mantenerse en valores de producción cercanos a los 500 BNPD, fracción en la cual se encuentra el máximo, luego decrece lentamente.

En la figura 4.14(a) se muestra la superposición de los datos seleccionados para validación y la salida neuronal donde se aprecia que el modelo se ajusta considerablemente a los datos. En la figura 4.14(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 7, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

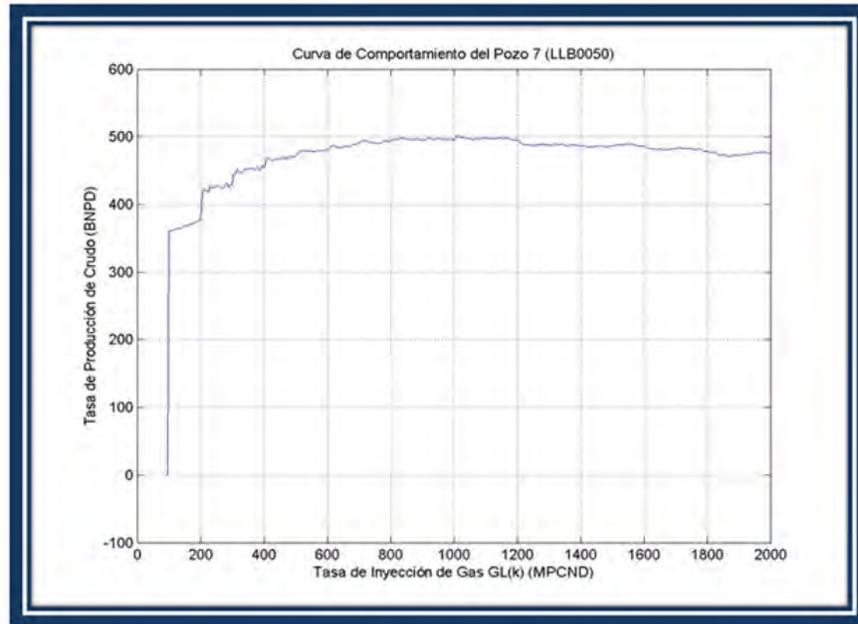
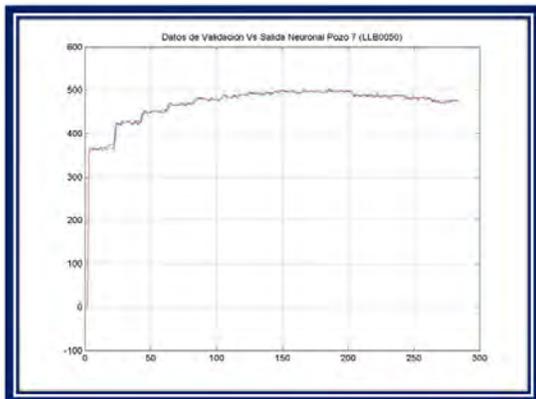
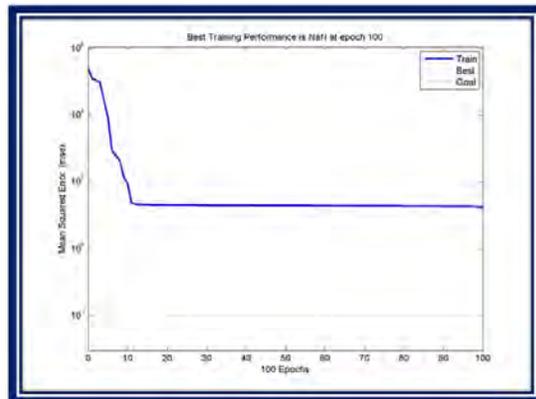


Figura 4.13: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 7 (LLB0050)



(a) BN(k) Vs BNn(k) del pozo 7 (LLB0050)



(b) ECM Vs. Épocas, pozo 7 (LLB0050)

Figura 4.14: Modelado Neuronal del Pozo 7 (LLB0050)

Pozo 8 (LLB0051).

En la figura 4.15 se muestra el comportamiento del pozo 8 (LLB0051) modelado mediante la red neuronal y se observa que para valores inferiores a 100 MPCND de la tasa de inyección, el pozo alcanza su máximo de producción, luego decrece rápidamente para tasas de inyección mayores, el presente modelo se acerca a los datos reales con un error porcentual del 1,10 %.

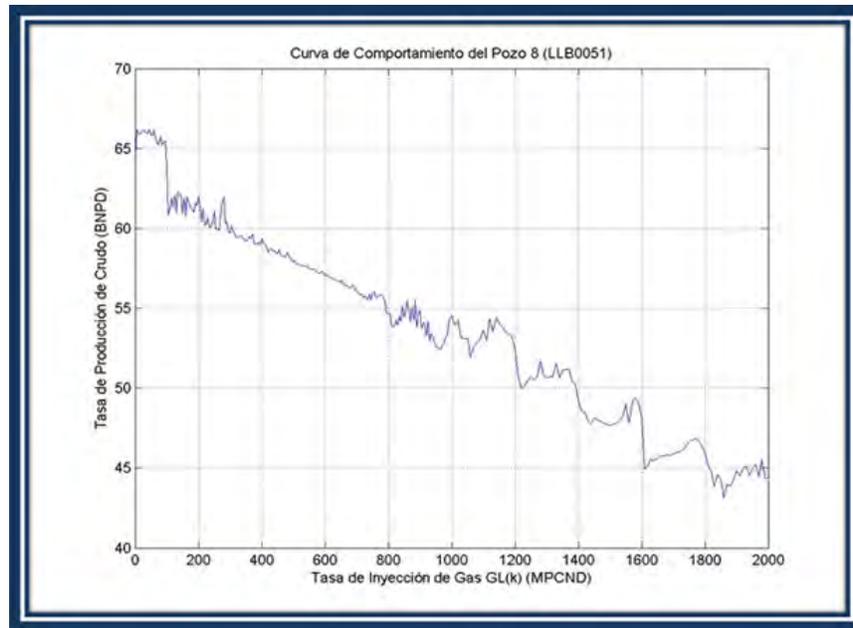
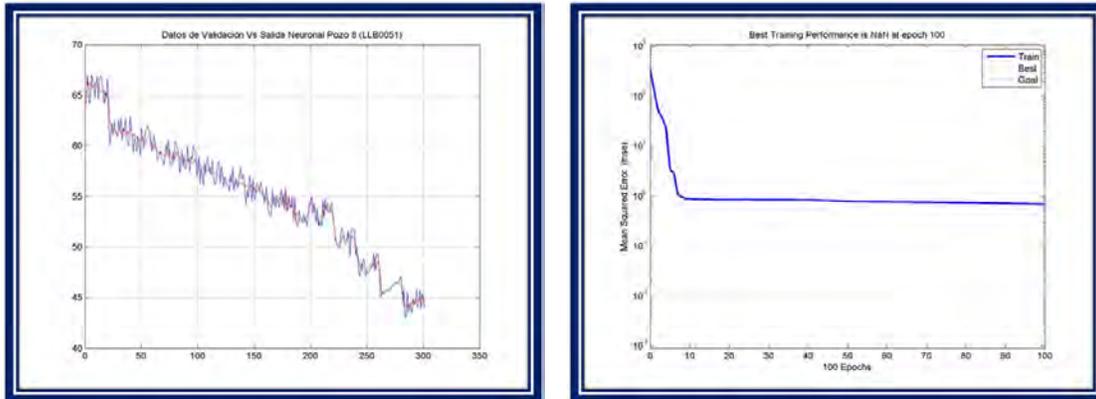


Figura 4.15: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 8 (LLB0051)

En la figura 4.16(a) se observa que el modelo representa de forma aceptable los datos introducidos para la validación. En la figura 4.16(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 8, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 8 (LLB0051)

(b) ECM Vs. Épocas, pozo 8 (LLB0051)

Figura 4.16: Modelado Neuronal del Pozo 8 (LLB0051)

Pozo 9 (LLB0052).

La figura 4.17 muestra el modelo neuronal del comportamiento del pozo 9 (LLB0052), el cual se acerca con un error porcentual del 1,79 % a los datos reales. Se observa que la curva es creciente para tasas de inyección de 1600 MPCND y una tasa de producción superior a los 200 BNPD a partir de la cual se puede encontrar el óptimo de la producción.

La figura 4.18(a) muestra una superposición de los datos reales seleccionados para validación y la salida neuronal, donde se aprecia que efectivamente el modelo obtenido representa de forma aceptable el comportamiento del pozo en estudio. En la figura 4.18(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 9, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

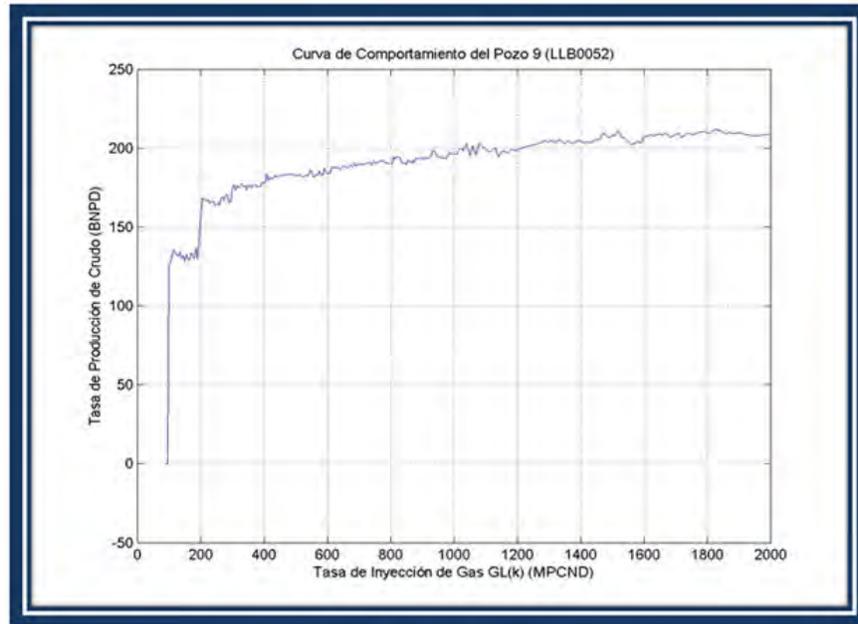
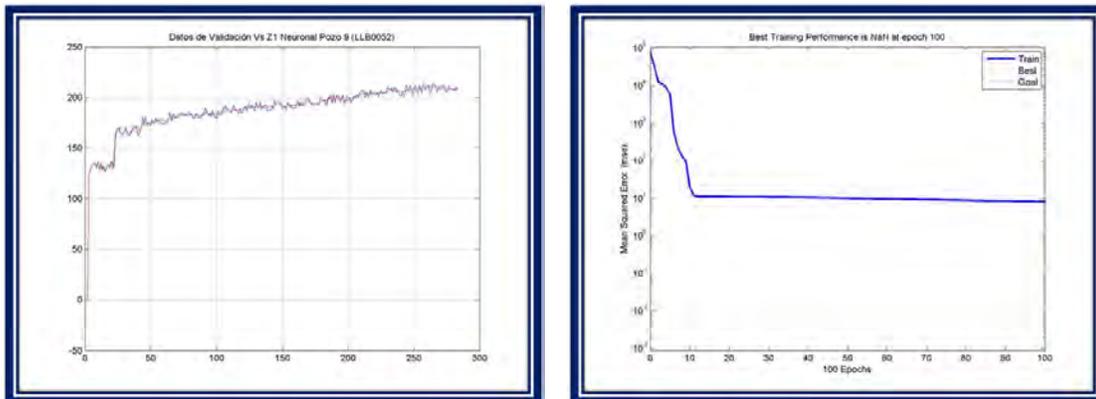


Figura 4.17: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 9 (LLB0052)



(a) BN(k) Vs BNn(k) del pozo 9 (LLB0052)

(b) ECM Vs. Épocas, pozo 9 (LLB0052)

Figura 4.18: Modelado Neuronal del Pozo 9 (LLB0052)

Pozo 10 (LLB0053).

El pozo 10 (LLB0053) tiene un comportamiento como el que se muestra en la figura 4.19. La curva es creciente hasta alcanzar un valor máximo de la producción superior a los 160 BNPD para una tasa de inyección que se acerca a los 800 MPCND, para valores superiores de la tasa de inyección los valores de la producción disminuyen, el modelo se aproxima a los datos reales con un error porcentual del 2,41 %.

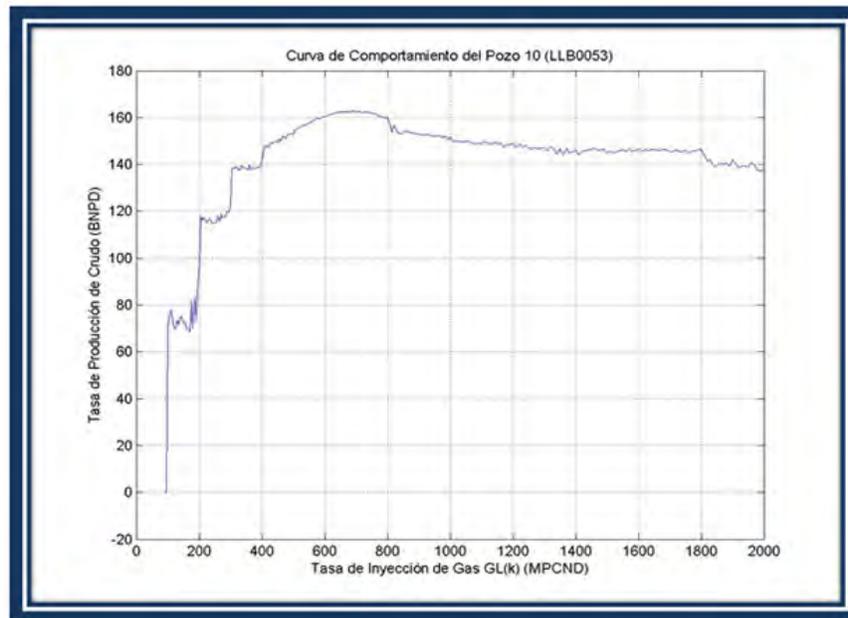
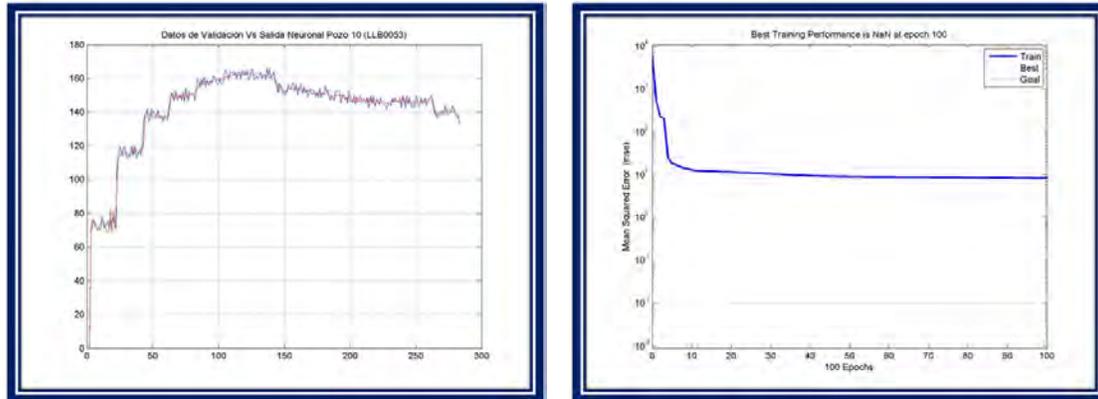


Figura 4.19: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 10 (LLB0053)

En la figura 4.20(a) se muestra que el modelo obtenido se acerca en gran medida a los datos reales seleccionados para la validación del modelo neuronal. En la figura 4.20(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 10, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 10 (LLB0053)

(b) ECM Vs. Épocas, pozo 10 (LLB0053)

Figura 4.20: Modelado Neuronal del Pozo 10 (LLB0053)

Pozo 11 (LLB0059).

La figura 4.21 muestra el modelo neuronal del comportamiento del pozo 11 (LLB0059). Se observa que la curva es creciente hasta alcanzar su máximo de producción para tasas de inyección de gas menores a los 450 MPCND, para tasas de inyección de gas superiores la curva decrece rápidamente, el modelo se acerca a los datos reales con un error porcentual del 0,45 %.

La figura 4.22(a) muestra una superposición de los datos reales seleccionados para validación y la curva de comportamiento mostrada en la figura , donde se aprecia que efectivamente el modelo obtenido representa de forma aceptable el comportamiento del pozo en estudio. En la figura 4.22(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 11, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

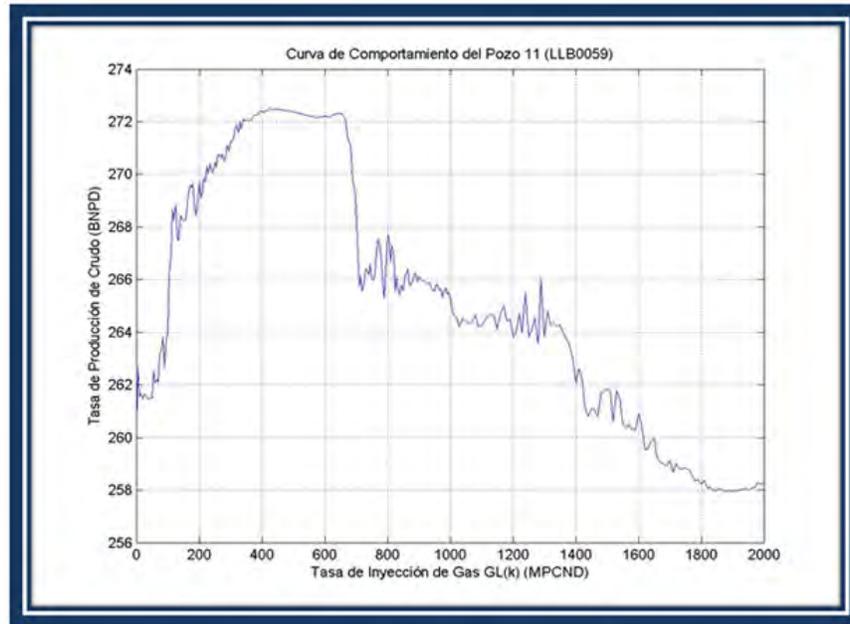
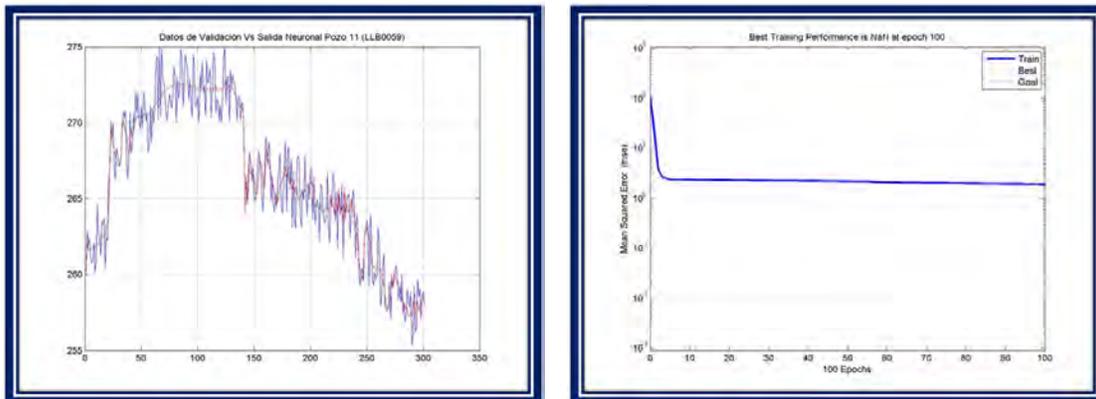


Figura 4.21: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 11 (LLB0059)



(a) BN(k) Vs BNn(k) del pozo 11 (LLB0059)

(b) ECM Vs. Épocas, pozo 11 (LLB0059)

Figura 4.22: Modelado Neuronal del Pozo 11 (LLB0059)

Pozo 12 (LLB0060).

La figura 4.23 muestra el modelo neuronal del comportamiento del pozo 12 (LLB0060), el cual se aproxima a los datos reales con un error porcentual del 1,99 %. Se observa que la curva es creciente para tasas de inyección de 1400 MPCND y una tasa de producción superior a los 120 BNPD a partir de la cual se puede encontrar el óptimo de la producción.

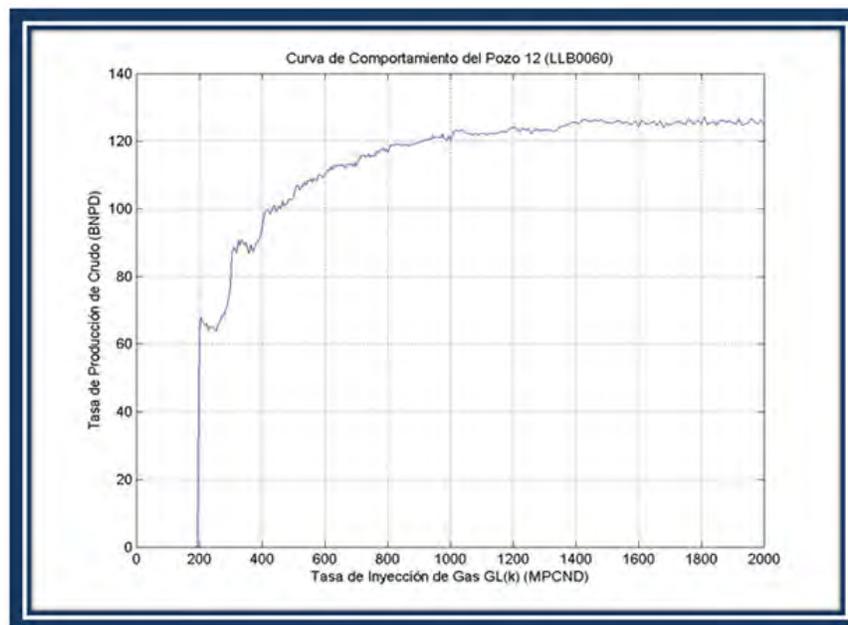
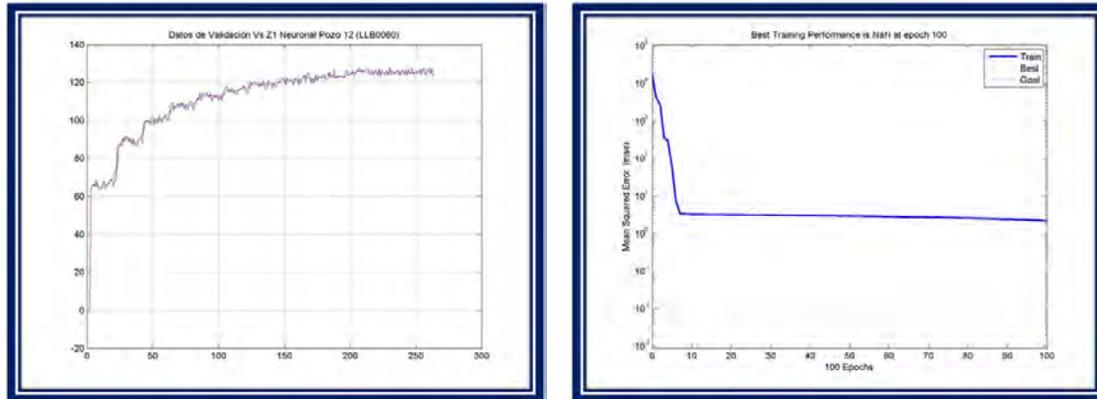


Figura 4.23: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 12 (LLB0060)

La figura 4.24(a) muestra una superposición de los datos seleccionados para validación y la curva de comportamiento del pozo donde se aprecia que efectivamente el modelo obtenido representa de forma aceptable el comportamiento del pozo en estudio. En la figura 4.24(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 12, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BN_n(k)$ del pozo 12 (LLB0060)

(b) ECM Vs. Épocas, pozo 12 (LLB0060)

Figura 4.24: Modelado Neuronal del Pozo 12 (LLB0060)

Pozo 13 (LLB0061).

La figura 4.25 muestra el modelo neuronal del comportamiento del pozo 13 (LLB0061), el cual se acerca a los datos reales con un error porcentual del 0,39 %. Se observa que la curva es creciente hasta alcanzar su máximo de producción para tasas de inyección de gas menores a los 800 MPCND, para tasas de inyección de gas superiores la curva decrece rápidamente.

La figura 4.26(a) muestra una superposición de los datos reales seleccionados para validación y la curva de comportamiento mostrada en la figura , donde se aprecia que efectivamente el modelo obtenido representa de forma aceptable el comportamiento del pozo en estudio. En la figura 4.26(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 13, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

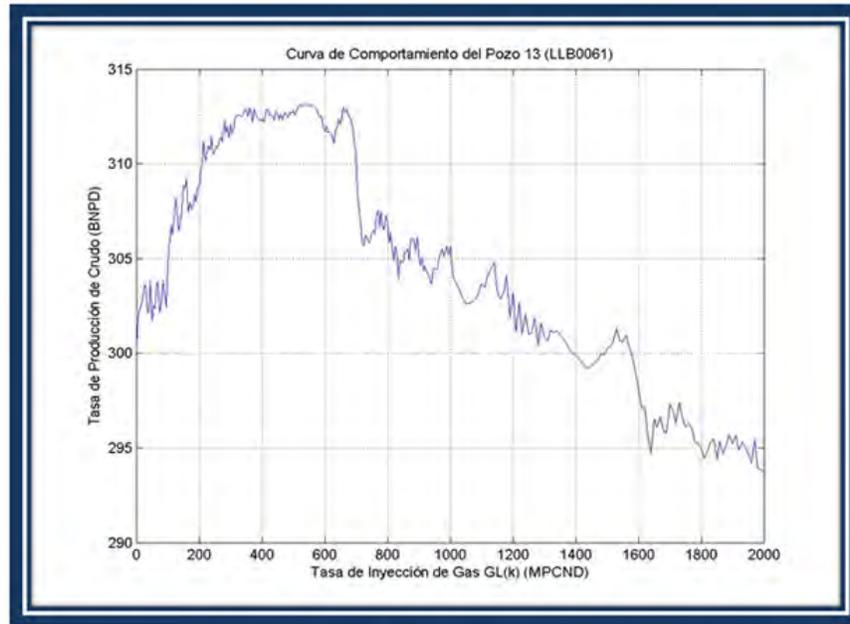
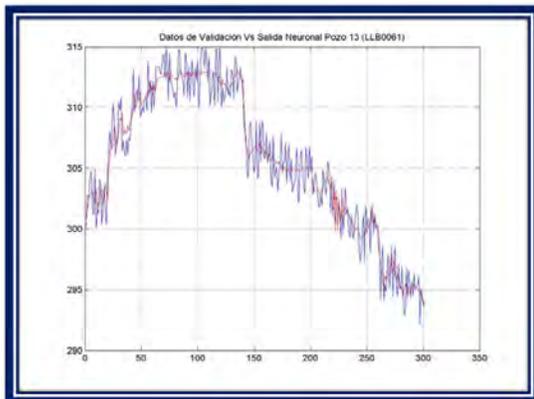
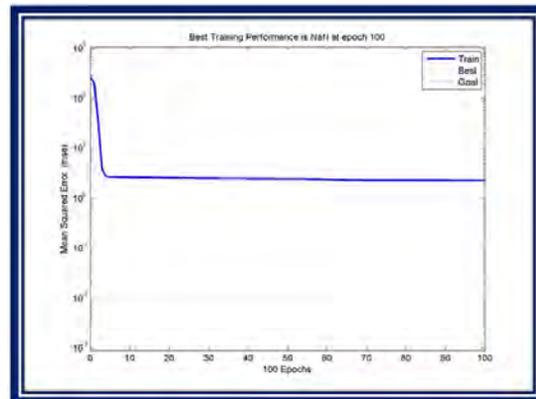


Figura 4.25: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 13 (LLB0061)



(a) BN(k) Vs BNn(k) del pozo 13 (LLB0061)



(b) ECM Vs. Épocas, pozo 13 (LLB0061)

Figura 4.26: Modelado Neuronal del Pozo 13 (LLB0061)

Pozo 14 (LLB0062).

En la figura 4.27 se observa que la tasa de de producción del pozo 14 (LLB0062) crece rápidamente hasta alcanzar un valor máximo, esto ocurre para valores de inyección menores a los 600 MPCND donde el valor de producción neta se acerca a los 405 BNPD, el modelo presentado se acerca a los datos reales con un error porcentual del 0,59 %.

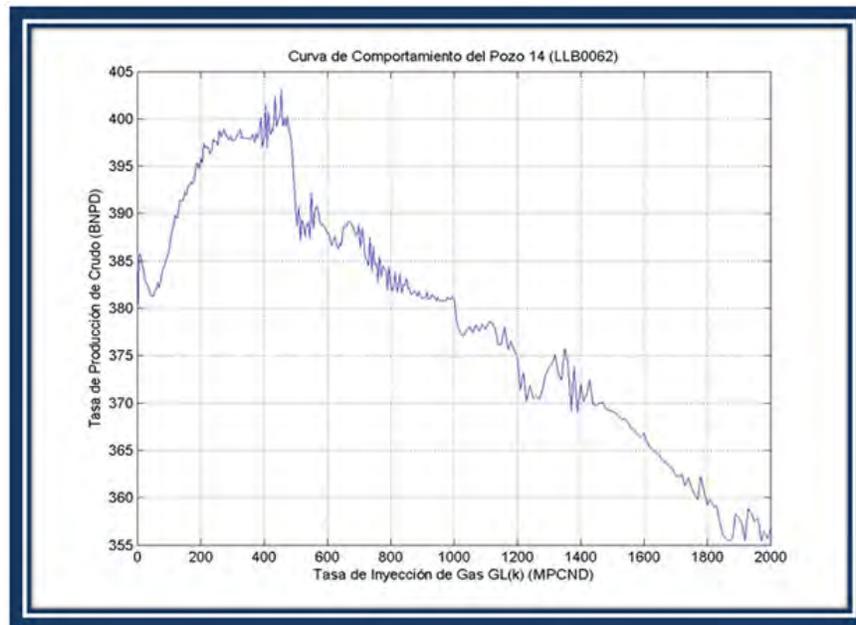
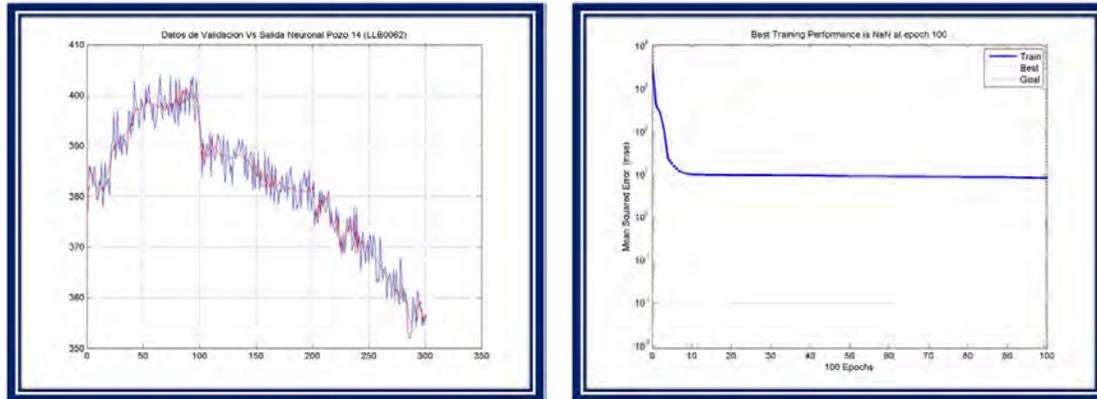


Figura 4.27: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 14 (LLB0062)

La figura 4.28(a) muestra que el modelo neuronal del comportamiento del pozo se ajusta a los datos utilizados para la validación. En la figura 4.28(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 14, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 14 (LLB0062)

(b) ECM Vs. Épocas, pozo 14 (LLB0061)

Figura 4.28: Modelado Neuronal del Pozo 14 (LLB0061)

Pozo 15 (LLB0063).

El pozo 15 (LLB0063) tiene un comportamiento como el que se muestra en la figura 4.29, el presente modelo se aproxima a los datos reales con un error porcentual del 1,85 %. La curva es creciente hasta alcanzar un valor máximo de la producción superior a los 100 BNPD para una tasa de inyección que se acerca a los 600 MPCND para valores superiores de la tasa de inyección los valores de la producción disminuyen lentamente.

En la figura 4.30(a) se muestra que el modelo obtenido se acerca en gran medida a los datos reales seleccionados para la validación del modelo neuronal. En la figura 4.30(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 10, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

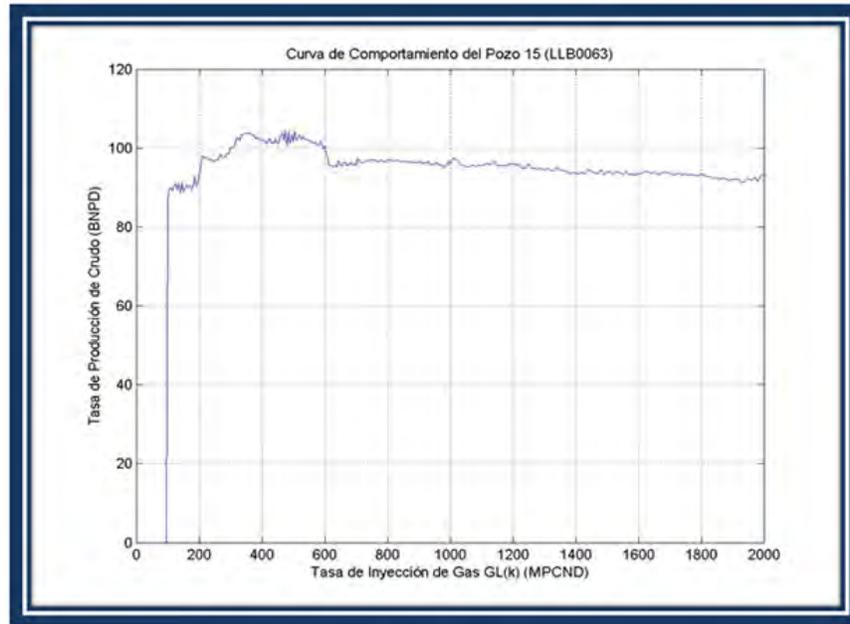
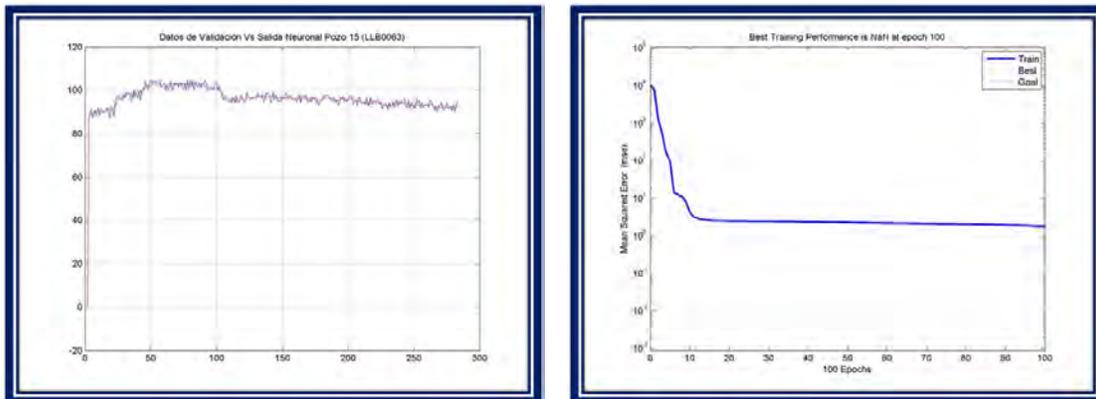


Figura 4.29: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 15 (LLB0063)



(a) BN(k) Vs BNn(k) del pozo 15 (LLB0063)

(b) ECM Vs. Épocas, pozo 15 (LLB0063)

Figura 4.30: Modelado Neuronal del Pozo 15 (LLB0063)

Pozo 16 (LLB0064).

El comportamiento del pozo 16 (LLB0064) se ve reflejado en la figura 4.31 la cual muestra un comportamiento creciente hasta alcanzar valores cercanos los 800 MPCND de gas de inyección, a partir de ese punto hay una pequeña porción de curva donde puede estar el óptimo de la producción. Para tasas de inyección superiores a los 1200 MPCND la curva decrece un poco y luego se mantiene, el modelo se acerca a los datos reales por medio de un error porcentual del 1,54 %.

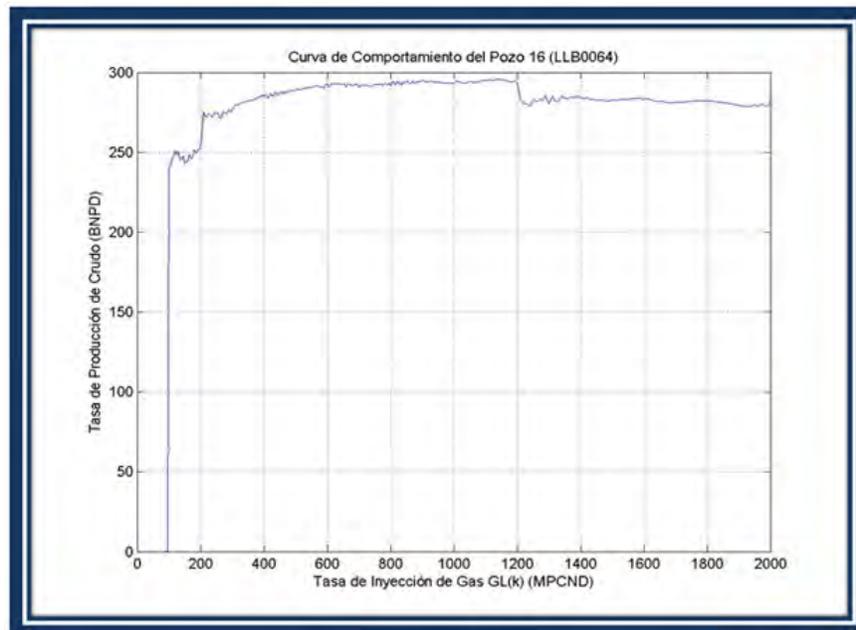
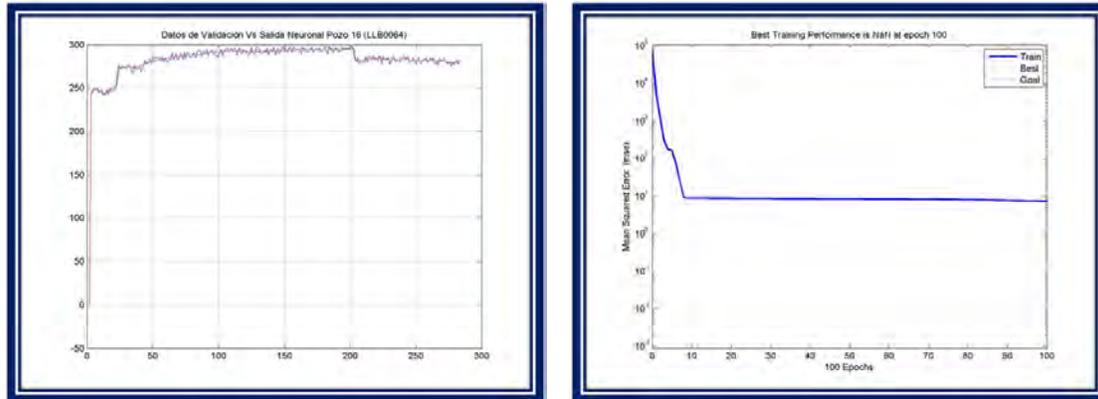


Figura 4.31: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 16 (LLB0064)

En la figura 4.32(a) se ve representado el mismo comportamiento superpuesto con la data seleccionada para la validación del modelo y se observa que hay una correspondencia aceptable entre ambos. En la figura 4.32(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 16, el cual decrece rápidamente hasta 20 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BNn(k)$ del pozo 16 (LLB0064)

(b) ECM Vs. Épocas, pozo 16 (LLB0064)

Figura 4.32: Modelado Neuronal del Pozo 16 (LLB0064)

Pozo 17 (LLB0065).

La figura 4.33 muestra el modelo neuronal del comportamiento del pozo 17 (LLB0065), el cual se aproxima a los datos reales con un error porcentual del 2,57 %. Se observa que la curva es creciente para tasas de inyección de 200 MPCND y una tasa de producción superior a los 140 BNPD a partir de la cual se puede encontrar el óptimo de la producción. Para valores de la tasa de inyección de gas superiores a los 800 MPCND la curva decrece.

La figura 4.34(a) muestra una superposición de los datos seleccionados para validación y la curva de comportamiento mostrada en la figura , donde se aprecia que efectivamente el modelo obtenido representa de forma aceptable el comportamiento del pozo en estudio. En la figura 4.34(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 17, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

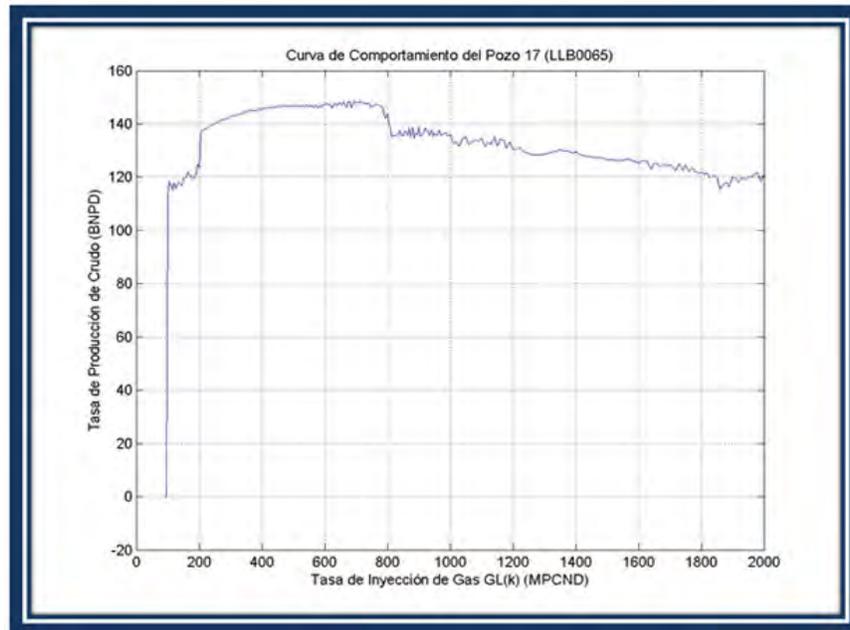
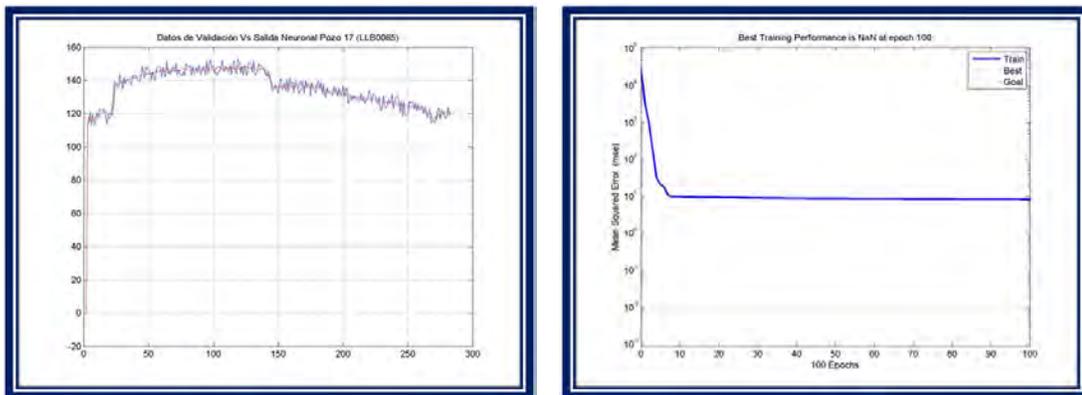


Figura 4.33: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 17 (LLB0065)



(a) BN(k) Vs BNN(k) del pozo 17 (LLB0065)

(b) ECM Vs. Épocas, pozo 17 (LLB0065)

Figura 4.34: Modelado Neuronal del Pozo 17 (LLB0065)

Pozo 18 (LLB0066).

En la figura 4.35 se observa el comportamiento del pozo 18 (LLB0066), donde la curva va creciendo lentamente hasta los 600 MPCND aproximadamente, a partir de ese punto la producción neta se mantiene en valores muy cercanos a los 95 BNPD, sección en la cual se puede encontrar el óptimo de la producción, este comportamiento se mantiene hasta una tasa de inyección aproximada 1400 MPCND donde decrece un poco y luego se mantiene en valores cercanos a los 80 BNPD. El presente modelo se aproxima a los datos reales utilizados para validación con un error porcentual del 1,99 %.

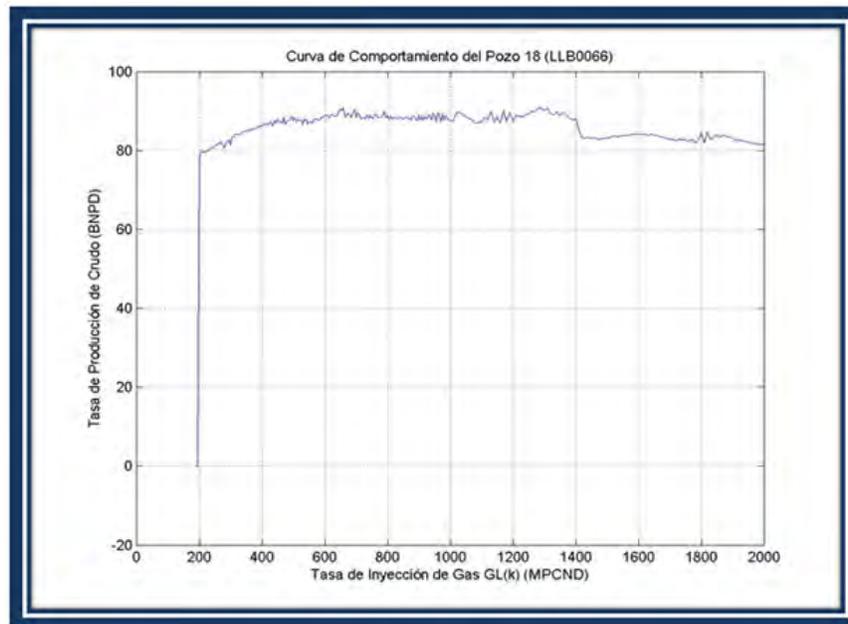
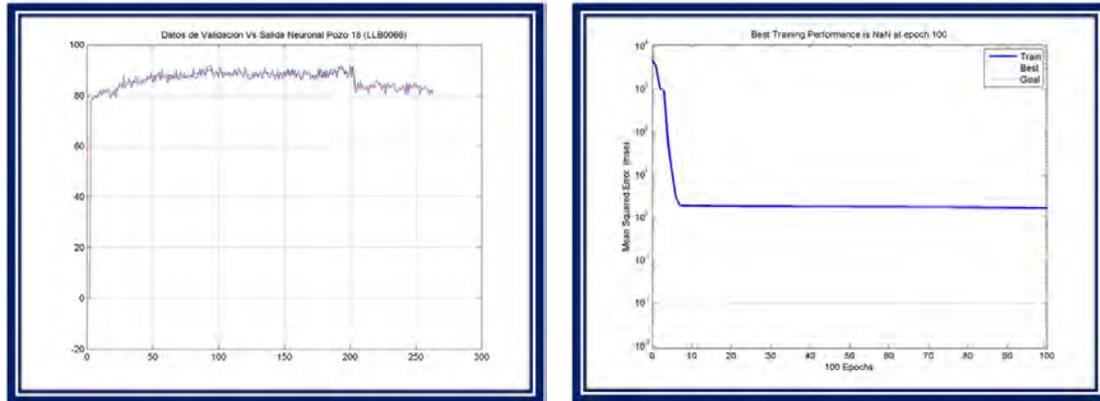


Figura 4.35: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 18 (LLB0066)

En la figura 4.36(a) se superpone el comportamiento del pozo descrito con la muestra de datos seleccionados para la validación del modelo neuronal y se observa que se aproximan eficientemente. En la figura 4.36(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 18, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número

(a) $BN(k)$ Vs $BNn(k)$ del pozo 18 (LLB0066)

(b) ECM Vs. Épocas, pozo 18 (LLB0066)

Figura 4.36: Modelado Neuronal del Pozo 18 (LLB0066)

máximo de ciclos de entrenamiento establecido como criterio de parada.

Pozo 19 (LLB0067).

En la figura 4.37 se muestra el comportamiento del pozo 19 (LLB0067) donde se observa que para valores inferiores a 400 MPCND de la tasa de inyección, el pozo alcanza su máximo de producción cuyo valor es superior a los 190 BNPD pero menor que 195 BNPD, luego decrece rápidamente para tasas de inyección mayores, el modelo se aproxima a los datos reales con un error porcentual del 0,61 %.

En la figura 4.38(a) se observa que el modelo representa de forma aceptable los datos introducidos para la validación. En la figura 4.38(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 19, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

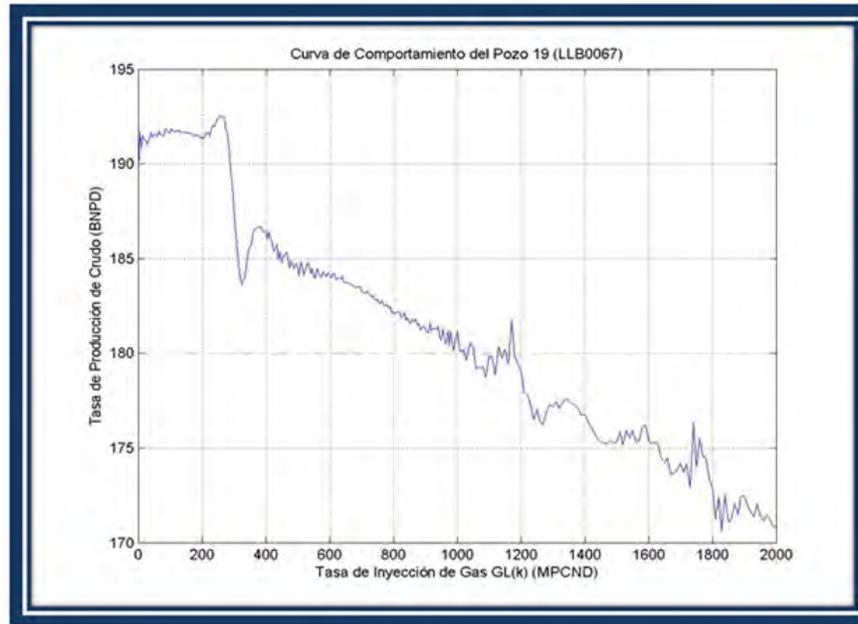
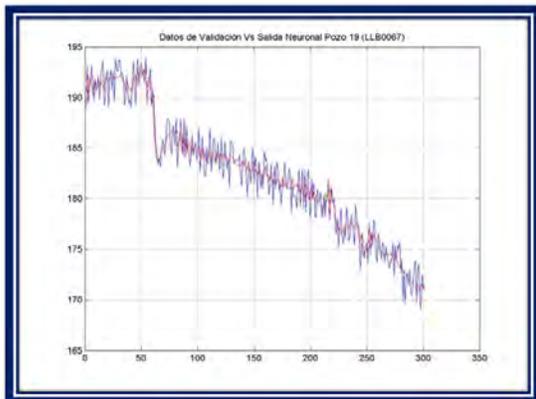
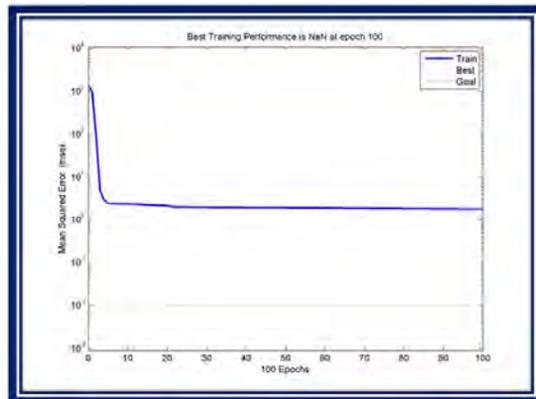


Figura 4.37: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 19 (LLB0067)



(a) BN(k) Vs BNn(k) del pozo 19 (LLB0067)



(b) ECM Vs. Épocas, pozo 19 (LLB0067)

Figura 4.38: Modelado Neuronal del Pozo 19 (LLB0067)

Pozo 20 (LLB0069).

En la figura 4.39 se muestra el comportamiento del pozo 20 (LLB0069) en el cual se observa que para valores inferiores a 200 MPCND de la tasa de inyección, el pozo alcanza su máximo de producción cuyo valor se aproxima a los 50 BNPD, luego decrece rápidamente para tasas de inyección mayores, el modelo se acerca a los datos reales con un error porcentual del 2,20 %.

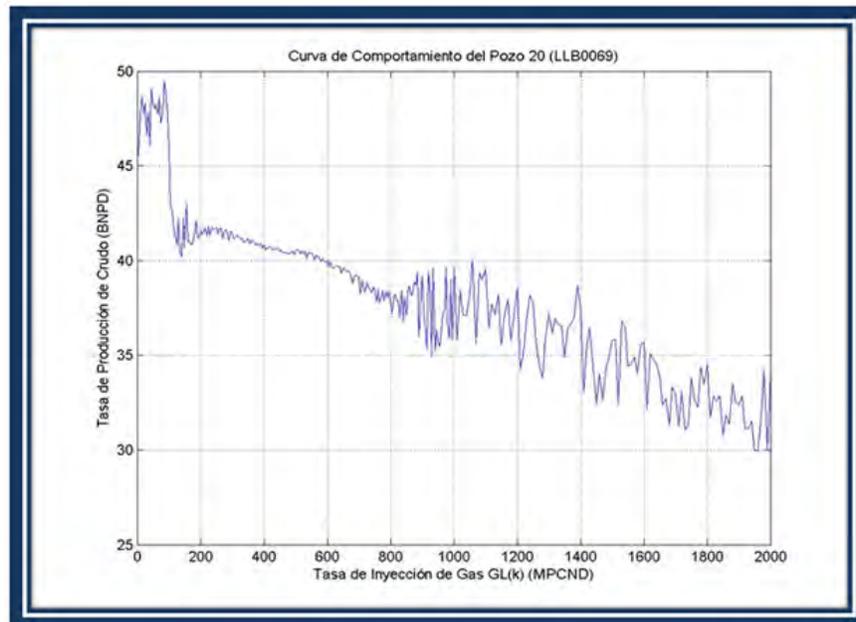
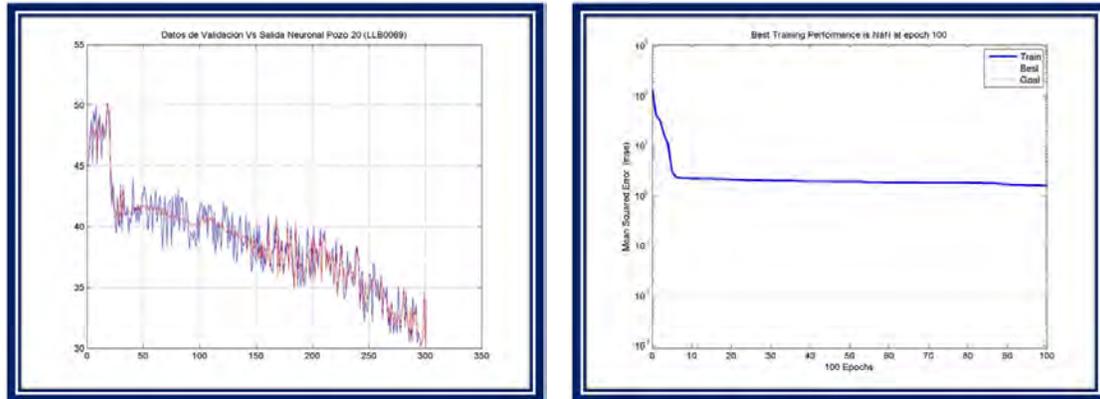


Figura 4.39: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 20 (LLB0069)

En la figura 4.40(a) se observa que el modelo representa de forma aceptable los datos introducidos para la validación. En la figura 4.40(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 20, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

(a) $BN(k)$ Vs $BN_n(k)$ del pozo 20 (LLB0069)

(b) ECM Vs. Épocas, pozo 20 (LLB0069)

Figura 4.40: Modelado Neuronal del Pozo 20 (LLB0069)

Pozo 21 (LLB0070).

En la figura 4.41 se observa el comportamiento del pozo 21 (LLB0070), donde la curva va creciendo lentamente hasta los 800 MPCND aproximadamente, a partir de ese punto la producción neta se mantiene en valores de la tasa de producción superiores a los 250 BNPD e inferiores a los 280 BNPD, sección en la cual se puede encontrar el óptimo de la producción, este comportamiento se mantiene hasta una tasa de inyección aproximada 1000 MPCND donde decrece lentamente en valores cercanos a los 250 BNPD. El presente modelo se acerca a los datos reales con un error porcentual del 1,81 %.

En la figura 4.42(a) se superpone la grafica del comportamiento del pozo descrita con la muestra de datos seleccionados para la validación del modelo neuronal y se observa que se aproximan eficientemente. En la figura 4.42(b) se observa el comportamiento del error cuadrático medio para el entrenamiento del modelo neuronal del pozo 18, el cual decrece rápidamente hasta 10 ciclos de entrenamiento y luego decrece lentamente hasta alcanzar el número máximo de ciclos de entrenamiento establecido como criterio de parada.

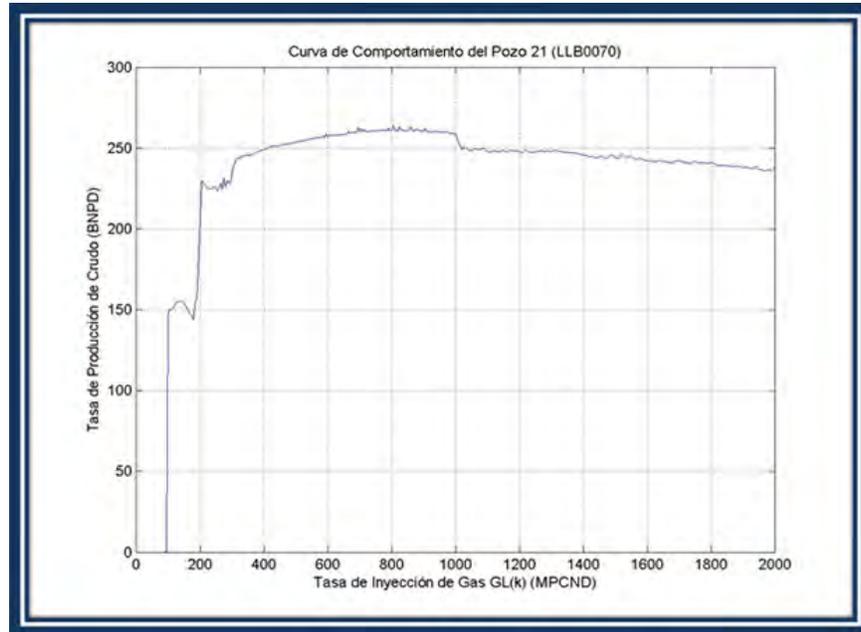
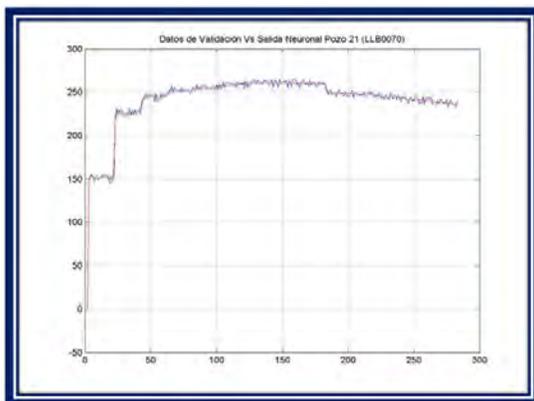
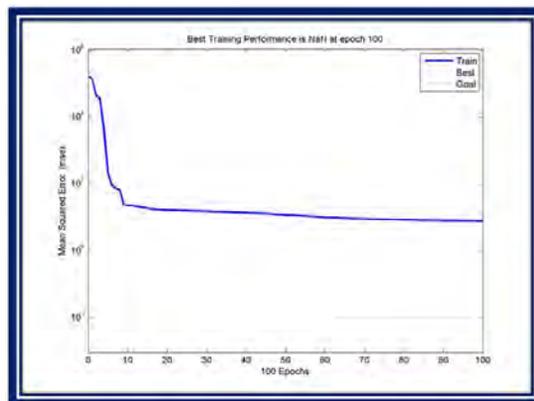


Figura 4.41: Tasa de Inyección de Gas GL(k) vs Tasa de Producción BN(k) del pozo 21 (LLB0070)



(a) BN(k) Vs BNn(k) del pozo 21 (LLB0070)



(b) ECM Vs. Épocas, pozo 21 (LLB0070)

Figura 4.42: Modelado Neuronal del Pozo 21 (LLB0070)

4.2. RESULTADOS DE OPTIMIZACIÓN.

En esta sección se discuten los resultados obtenidos a partir del Algoritmo Evolutivo NSGAI aplicado a el problema de optimización multi-objetivo propuesto en esta investigación. La codificación fue realizada en el lenguaje matemático MATLAB. Las funciones utilizadas del ordenamiento no dominado y los operadores genéticos están disponibles en [Mathworks, 2006].

4.2.1. Jerarquización de los pozos en estudio.

En la tabla 4.2 contiene el resultado de la aplicación del algoritmo de no dominación a los valores actuales de inyección y producción, donde se observa el orden de los pozos según los criterios establecidos. Según este resultado el mejor pozo es el 7 (LLB0050) por lo cual se pondera con el mayor valor de Q y el pozo que tiene las condiciones mas bajas es el pozo 12 (LLB0060) al cual le corresponde el menor valor de Q .

4.2.2. Optimización Evolutiva Multiobjetivo.

El experimento realizado y mostrado en esta sección corresponde a las corridas del algoritmo NSGAI. Los parámetros iniciales se resumen en la tabla A.1.

Los resultados mostrados a continuación corresponden al conjunto de soluciones factibles que alcanza el algoritmo evolutivo multiobjetivo y que satisface el problema de optimización. Se tiene un conjunto de 40 soluciones factibles para cada pozo, debido a que el algoritmo evolutivo preserva el tamaño de la población para cada pozo. Cada alternativa contiene un valor de la inyección de gas en el instante k ($X(k)$) y dos retrasos de la misma ($X(k-1)$ y $X(k-2)$) y el valor de la producción neta en el instante $k-1$ y $e(Y(k-1))$ como las

Tabla 4.2: Jeraquización del Campo en estudio según la mínima inyección y la máxima producción de crudo.

Pozo	Inyección MCND	Producción BNPD	Jerarquía Q
7	900	493	1
14	300	394	0,95238095
19	200	189	0,9047619
5	500	343	0,85714286
8	200	62	0,80952381
13	300	310	0,76190476
6	300	122	0,71428571
11	400	270	0,66666667
16	600	285	0,61904762
20	200	44	0,57142857
3	600	236	0,52380952
15	300	100	0,47619048
17	500	143	0,42857143
21	700	255	0,38095238
1	1200	165	0,33333333
2	600	163	0,28571429
4	400	78	0,23809524
9	1800	205	0,19047619
18	500	86	0,14285714
10	600	157	0,0952381
12	1600	123	0,04761905

Tabla 4.3: Parámetros de entrada al algoritmo evolutivo.

Número de Generaciones	250
Tamaño de la población	840
Probabilidad de cruce	0,1
Probabilidad de mutación	0,9

entradas del modelo, adicionalmente la producción neta en el instante actual $Y(k)$ y el correspondiente índice de productividad J . Las soluciones factibles para el pozo 1 se muestran en la tabla A.2:

Tabla 4.4: Conjunto de Soluciones Factibles para el pozo 1 (LLB0018).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1230	1220	1210	172,05	174,90	584280,50
2	1330	1320	1310	168,72	174,47	697380,50
3	1370	1360	1350	172,28	174,30	745420,50
4	1250	1240	1230	166,79	174,23	606100,50
5	1310	1300	1290	170,26	174,03	673960,50
6	1120	1110	1100	168,12	173,67	471420,50
7	1010	1000	0	164,00	173,53	370660,50
8	1350	1340	1330	165,73	173,28	721200,50
9	1020	1010	1000	173,53	173,07	379320,50
10	1290	1280	1270	167,29	172,37	650940,50
11	1360	1350	1340	173,28	172,28	733260,50
12	1220	1210	1200	169,55	172,05	573520,50
13	1310	1300	1290	170,25	172,00	674040,84
14	1060	1050	1040	165,62	171,70	414960,50
15	1160	1150	1140	166,22	171,42	511060,50
16	1212	1200	1189	165,08	170,83	564706,56
17	1340	1330	1320	174,47	170,71	709329,23
18	1308	1300	1291	170,19	170,56	671943,61
19	1100	1090	1080	169,58	170,39	452200,50
20	1300	1290	1280	172,37	170,26	662400,50
21	1140	1130	1120	165,18	170,23	491040,50
22	1250	1240	1230	166,71	169,84	606112,06
23	1250	1239	1232	166,82	169,76	606640,44
24	1208	1198	1186	165,00	169,70	560322,91
25	1090	1080	1070	167,64	169,58	442740,50
26	1210	1200	1190	165,00	169,55	562860,50
27	1220	1210	1198	169,57	169,40	573789,35
28	1210	1201	1188	165,00	169,20	562340,41
29	1373	1356	1352	172,28	169,18	748851,54
30	1210	1200	1190	165,01	169,13	562879,92
31	1390	1380	1370	167,43	169,12	770040,50
32	1210	1200	1190	165,00	169,10	562859,55
33	1360	1350	1340	173,30	168,87	733317,66
34	1320	1310	1300	174,03	168,72	685620,50
35	1040	1030	1020	167,42	168,55	396940,50
36	1110	1100	1090	170,39	168,12	461760,50
37	1230	1220	1210	172,05	168,02	584182,67
38	1160	1150	1140	166,15	167,91	511076,78
39	1260	1250	1240	174,23	167,85	617160,50
40	1360	1350	1342	173,25	167,81	732956,57

Las soluciones factibles generadas por el algoritmo evolutivo multi-objetivo se encuentran ordenadas de acuerdo al frente de Pareto y a la distancia de agrupamiento de las mismas, en forma creciente, por lo tanto, las mejores soluciones candidatas se encuentran al inicio de las tablas anteriores. A partir de las soluciones factibles se selecciona un óptimo candidato para cada pozo. Este proceso de selección puede ir sustentado por la opinión de los expertos de campo. Para consultar los valores resultantes de los pozos 2-21 consultar el Apéndice A.

Tabla 4.5: Soluciones Óptimas Seleccionadas.

Pozos	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
7	1095	1090	1085	497,72	503,01	200344,50
14	440	435	430	401,40	403,91	1152,00
19	115	110	105	191,00	193,89	2664,50
5	670	665	660	349,22	354,79	72200,00
8	100	0	0	0,00	63,00	840,50
13	410	405	400	314,00	314,94	5100,50
6	440	435	430	117,80	144,04	52788,91
11	345	340	335	271,75	274,88	2888,00
16	780	775	770	294,56	297,35	124002,00
20	100	0	0	0,00	52,02	1625,70
3	775	770	765	242,71	245,37	159612,50
15	330	325	320	104,48	104,97	26450,00
17	510	505	500	143,65	152,85	67344,50
21	885	880	875	257,31	264,82	200344,50
1	1370	1360	1350	172,28	174,30	745420,50
2	715	710	705	169,42	172,99	174050,00
4	695	690	685	80,16	82,92	193442,00
9	1930	1920	1910	206,22	214,43	1533000,50
18	670	665	660	88,88	91,75	170528,00
10	775	770	765	161,28	165,94	189728,00
12	1610	1600	0	123,03	311,32	1143072,00
TOTAL	14760	14450	12750	4187	4584	5066599

La tabla A.3 muestra una propuesta de soluciones óptimas en base a jerarquía de Pareto. Es importante mencionar que las soluciones factibles seleccionadas cumplen con los criterios de producción mínima requerida ($Y_{\min} = 3803,4429$ BNPD) en campo y la capacidad de gas disponible para inyección ($X_{\max} = 20718,75$ MPCND).

En la siguiente tabla A.4 se comparan los resultados obtenidos mediante el modelo de optimización con los valores actuales de inyección y de producción de la Estación de Flujo en estudio.

Tabla 4.6: Resultados de la Distribución para La Producción Actual.

Número	Pozos	ACTUAL		OPTIMIZACIÓN	
		Inyección MPCND	Producción BNPD	Inyección MPCND	Producción BNPD
7	LLB0050	900	493	1095	503,01
14	LLB0062	300	394	440	403,91
19	LLB0067	200	189	115	193,89
5	LLB0042	500	343	670	354,79
8	LLB0051	200	62	100	63,00
13	LLB0061	300	310	410	314,94
6	LLB0047	300	122	440	144,04
11	LLB0059	400	270	345	274,88
16	LLB0064	600	285	780	297,35
20	LLB0069	200	44	100	52,02
3	LLB0022	600	236	775	245,37
15	LLB0063	300	100	330	104,97
17	LLB0065	500	143	510	152,85
21	LLB0070	700	255	885	264,82
1	LLB0018	1200	165	1370	174,30
2	LLB0021	600	163	715	172,99
4	LLB0026	400	78	695	82,92
9	LLB0052	1800	205	1930	214,43
18	LLB0066	500	86	670	91,75
10	LLB0053	600	157	775	165,94
12	LLB0060	1600	123	1610	311,32
	TOTAL	12700	4223	14759,9484	4583,50133

En la tabla A.4 se observan los 21 pozos estudiados, ordenados tomando en cuenta

la máxima producción neta de crudo y la menor tasa de inyección de gas, mediante el algoritmo de la búsqueda no dominada.

Tabla 4.7: Jerarquización de los pozos en estudio.

		Inyección	Producción
Pozo	Etiqueta	MPCND	BNPD
7	LLB0050	1095	503,01
8	LLB0051	100	63
11	LLB0059	345	274,88
13	LLB0061	410	314,94
14	LLB0062	440	403,91
19	LLB0067	115	193,89
5	LLB0042	670	354,79
6	LLB0047	440	144,04
15	LLB0063	330	104,97
17	LLB0065	510	152,85
20	LLB0069	100	52,02
2	LLB0021	715	172,99
3	LLB0022	775	245,37
12	LLB0060	1610	311,32
16	LLB0064	780	297,35
18	LLB0066	670	91,75
4	LLB0026	695	82,92
10	LLB0053	775	165,94
21	LLB0070	885	264,82
1	LLB0018	1370	174,3
9	LLB0052	1930	214,43

En la tabla A.5 se muestran los resultados de la aplicación de algoritmo de no dominación sobre los resultados de optimización y se nota que el mejor pozo sigue siendo el pozo 7 (LLB0050), sin embargo el último pozo es el 9 (LLB0052).

Capítulo 5

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones.

- Se elaboró una aplicación que proporciona apoyo operacional y que permite generar respuestas eficientes en cuanto a la distribución del gas de alta presión disponible para inyección.
- Las redes neuronales obtuvieron un buen desempeño en el modelado de la curva de rendimiento de los pozos con coeficiente de correlación en promedio de 0.9731 para validación lo que demuestra su alta capacidad de generalización.
- El algoritmo evolutivo demostró ser una herramienta eficiente en la solución de problemas de objetivos múltiples.
- La búsqueda no dominada puede ser aplicada por si sólo en la jerarquización de múltiples variables permitiendo el manejo de contingencias mediante la simulación de varios escenarios.
- La matriz de inyecciones y tasas de producción resultante está dentro de las restric-

ciones propias del campo en estudio.

- El desempeño del algoritmo evolutivo determinó un ahorro del gas consumido por los pozos en la muestra seleccionada demostrando una distribución global eficiente del gas disponible para inyección.

5.2. Recomendaciones.

- Implantar las herramientas tecnológicas requerida para que este tipo de aplicaciones accedan a las bases de datos de producción, lo cual permitirá simular múltiples escenarios y explotar las funcionalidades de la herramienta.
- Aplicar el modelo de optimización propuesto en esta investigación, como herramienta para la toma de decisiones en el modelado de contingencias en la unidad de explotación LAGOMAR y hacerlo extensible a otras áreas operacionales.
- Estimular el uso de las redes neuronales para el desarrollo de modelos en las áreas de producción y yacimientos, así como los algoritmos evolutivos multi - objetivo en problemas de distribución y optimización de recursos.

Bibliografía

[Aguilar, C and Rivas, F., 2001] Aguilar, C and Rivas, F. (2001). *Introducción a las Técnicas de Computación Inteligente*. Universidad de los Andes.

[Aldana, V. and Salas, R., 2001] Aldana, V. and Salas, R. (2001). Optimización de la tasa de inyección de gas lift basada en inteligencia artificial. *Petróleos de Venezuela*.

[Bacpropagation, 2008] Bacpropagation (2008). Backpropagation con levenberg marquardt. <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/LevMarqB.htm>, Consultado en agosto de 2008.

[Barberii, 1998] Barberii, E. (1998). *El Pozo Ilustrado*. Fondo editorial del centro internacional de educación y desarrollo.

[Charrouf, 2001] Charrouf, R. (2001). Optimización de la tasa de inyección de gas lift basada en inteligencia artificial. *Petróleos de Venezuela*.

[Coello, 2003] Coello, C. (2003). Evolutionary multiobjective optimization: Current and future challenges. Disponible en: <http://delta.cs.cinvestav.mx/~ccoello/conferences/coello-wsc7.pdf.gz>, Consultado en Septiembre de 2008.

[Computación Evolutiva, 2007] Computación Evolutiva (2007). Computación evolutiva. Disponible en: http://es.wikipedia.org/wiki/Computacion_evolutiva, Consultado en agosto de 2008.

- [Deb, K. and Agrawal, R., 1994] Deb, K. and Agrawal, R. (1994). Simulated binary crossover for continuous search space. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.26.8485> , Consultado en junio de 2008.
- [Deb, K. et al., 2002] Deb, K., Agrawal, S., Pratap, A., and Meyarivan, T. (2002). A fast and elitist multi-objective genetic algorithm: Nsga-ii. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.18.7210> , Consultado en junio de 2008.
- [Eficiencia de Pareto, 2008] Eficiencia de Pareto (2008). Eficiencia de Pareto. Disponible en: http://es.wikipedia.org/wiki/Eficiencia_de_Pareto, Consultado en agosto de 2008.
- [Felix, 2008] Felix, F. (2008). Inteligencia artificial. Disponible en: http://es.wikibooks.org/wiki/Inteligencia_artificial, Consultado en agosto de 2008.
- [Fonseca, C. and Fleming, P., 1995] Fonseca, C. and Fleming, P. (1995). An overview of evolutionary algorithms in multiobjective optimization. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.108.8521> , Consultado en junio de 2008.
- [García, 2004] García, L. (2004). Uso y aplicaciones de la inteligencia artificial. Disponible en: <http://www.uv.mx/cienciahombre/revistae/vol17num3/articulos/inteligencia/index.htm>, Consultado en agosto de 2008.
- [González, 2008] González, J. (2008). *Fundamentos de Ingeniería de Producción*. Manual Interno PDVSA.
- [Heurística, 2008] Heurística (2008). Heurística. Disponible en: <http://es.wikipedia.org/wiki/Heuristica>, Consultado en diciembre de 2008.

- [Industria Petrolera, 2008] Industria Petrolera (2008). Industria petrolera, mecanismos de producción. Disponible en: <http://industria-petrolera.blogspot.com/search/label/Inyeccias>, Consultado en Julio de 2008.
- [Jennings, Dennis R. and et al., 2000] Jennings, Dennis R. and et al., F. (2000). *Petroleum Accounting Principles, Procedures and Issues. (5th Edition)*. Professional Development Institute. University of Texas.
- [Jiménez, F. and Verdegay, J., 1998] Jiménez, F. and Verdegay, J. (1998). Constrained multiobjective optimization by evolutionary algorithm. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.31.1895> , Consultado en junio de 2008.
- [Landa, 2008] Landa, R. (2008). Algoritmos culturales aplicados a la optimización con restricciones y optimización multiobjetivo. Disponible en: http://delta.cs.cinvestav.mx/ccollo/tesis/tesis_landa.pdf.gz, Consultado en agosto de 2008.
- [Maggiolo, 2005] Maggiolo, R. (2005). *Ingeniería de Producción. Análisis Nodal*. Manual Interno PDVSA. Programa de Adiestramiento.
- [Mathworks, 2006] Mathworks (2006). Nsga ii a multi-objective optimization algorithm. Disponible en: <http://www.mathworks.com/matlabcentral/fileexchange/10429>, Consultado en agosto de 2008.
- [Mezura, 2001] Mezura, E. (2001). Uso de la tecnica multiobjetivo npga para el manejo de restricciones en algoritmos genéticos. Disponible en: http://delta.cs.cinvestav.mx/ccollo/tesis/tesis_mezura.ps.gz, Consultado en agosto de 2008.
- [Queipo, N. and Guevara, F., 2000] Queipo, N. and Guevara, F. (2000). Técnicas de computación emergente y fundamentos de petróleo. *Universidad del Zulia*.

- [Red Neuronal Artificial, 2008] Red Neuronal Artificial (2008). Red neuronal artificial. Disponible en: http://es.wikipedia.org/wiki/Red_neuronal_artificial, Consultado en noviembre de 2008.
- [Redes de Retropropagación, 2008] Redes de Retropropagación (2008). Redes de retropropagación. Disponible en: http://www.geocities.com/siliconvalley/campus/9756/Tutorial/RNA_backprop.htm, Consultado en agosto de 2008.
- [Santana, V. and Coello, C., 2002] Santana, V. and Coello, C. (2002). Una introducción a la computación evolutiva y algunas de sus aplicaciones en economía y finanzas. Disponible en: <http://www.upo.es/RevMetCuant/art4.pdf>, Consultado en Julio de 2008.
- [Yacimientos de Gas, 2008] Yacimientos de Gas (2008). Yacimientos de gas, levantamiento artificial por gas. Disponible en: <http://yacimientos-de-gas.blogspot.com/2008/11/levantamiento-artificial-por-gas.html>, Consultado en Julio de 2008.
- [Zamora, 1985] Zamora, J. (1985). *Producción de Petróleo. Principios Fundamentales. Segunda Edición.*
- [Zitzler, E. et al., 2000] Zitzler, E., Deb, K., and Thiele, L. (2000). Comparison of multiobjective evolutionary algorithms: Empirical results. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.30.5848>, Consultado en octubre de 2008.
- [Zitzler, E. et al., 2004] Zitzler, E., Laumanns, M., and Bleuler, S. (2004). A tutorial on evolutionary multiobjective optimization. Disponible en: <http://www.cs.cinvestav.mx/emooworkgroup/zitzler04.pdf>, Consultado en agosto de 2008.

Apéndice A

Resultados Parciales NSGAI

En este apéndice se muestran las tablas resultantes de la corrida del algoritmo evolutivo multiobjetivo de los pozos 2 - 21. A partir de cada una de estas tablas se seleccionaron los mejores candidatos para cada pozo.

Tabla A.1: Conjunto de Soluciones Factibles para el pozo 1 (LLB0018).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1230	1220	1210	172,05	174,90	584280,50
2	1330	1320	1310	168,72	174,47	697380,50
3	1370	1360	1350	172,28	174,30	745420,50
4	1250	1240	1230	166,79	174,23	606100,50
5	1310	1300	1290	170,26	174,03	673960,50
6	1120	1110	1100	168,12	173,67	471420,50
7	1010	1000	0	164,00	173,53	370660,50
8	1350	1340	1330	165,73	173,28	721200,50
9	1020	1010	1000	173,53	173,07	379320,50
10	1290	1280	1270	167,29	172,37	650940,50
11	1360	1350	1340	173,28	172,28	733260,50
12	1220	1210	1200	169,55	172,05	573520,50
13	1310	1300	1290	170,25	172,00	674040,84
14	1060	1050	1040	165,62	171,70	414960,50
15	1160	1150	1140	166,22	171,42	511060,50
16	1212	1200	1189	165,08	170,83	564706,56
17	1340	1330	1320	174,47	170,71	709329,23
18	1308	1300	1291	170,19	170,56	671943,61
19	1100	1090	1080	169,58	170,39	452200,50
20	1300	1290	1280	172,37	170,26	662400,50
21	1140	1130	1120	165,18	170,23	491040,50
22	1250	1240	1230	166,71	169,84	606112,06
23	1250	1239	1232	166,82	169,76	606640,44
24	1208	1198	1186	165,00	169,70	560322,91
25	1090	1080	1070	167,64	169,58	442740,50
26	1210	1200	1190	165,00	169,55	562860,50
27	1220	1210	1198	169,57	169,40	573789,35
28	1210	1201	1188	165,00	169,20	562340,41
29	1373	1356	1352	172,28	169,18	748851,54
30	1210	1200	1190	165,01	169,13	562879,92
31	1390	1380	1370	167,43	169,12	770040,50
32	1210	1200	1190	165,00	169,10	562859,55
33	1360	1350	1340	173,30	168,87	733317,66
34	1320	1310	1300	174,03	168,72	685620,50
35	1040	1030	1020	167,42	168,55	396940,50
36	1110	1100	1090	170,39	168,12	461760,50
37	1230	1220	1210	172,05	168,02	584182,67
38	1160	1150	1140	166,15	167,91	511076,78
39	1260	1250	1240	174,23	167,85	617160,50
40	1360	1350	1342	173,25	167,81	732956,57

Tabla A.2: Conjunto de Soluciones Factibles para el pozo 2 (LLB0021).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	775	770	765	242,71	245,37	159612,50
2	660	655	650	242,28	245,34	101250,00
3	670	665	660	236,79	245,05	105800,00
4	725	720	715	243,24	245,02	132612,50
5	735	730	725	241,42	245,00	137812,50
6	705	700	695	236,00	244,97	122512,50
7	760	755	750	237,84	244,39	151250,00
8	780	775	770	245,37	244,24	162450,00
9	710	705	700	244,97	243,80	125000,00
10	785	780	775	244,24	243,41	165312,50
11	610	605	600	242,17	243,34	80000,00
12	740	735	730	245,00	243,34	140450,00
13	720	715	710	238,22	243,24	130050,00
14	690	685	680	242,16	242,98	115200,00
15	675	670	665	245,05	242,96	108112,50
16	680	675	670	242,96	242,89	110450,00
17	770	765	760	236,30	242,71	156800,00
18	630	625	620	241,45	242,70	88200,00
19	795	790	785	236,07	242,45	171112,50
20	750	745	740	242,14	242,36	145800,00
21	655	650	645	236,00	242,28	99012,50
22	605	600	0	236,00	242,17	78012,50
23	685	680	675	242,89	242,16	112812,50
24	745	740	735	243,34	242,14	143112,50
25	781	775	770	245,37	241,91	162919,88
26	780	775	770	245,34	241,73	162416,18
27	745	740	735	243,16	241,56	143079,00
28	745	740	735	243,38	241,56	143152,90
29	745	740	735	243,34	241,55	143117,62
30	745	740	735	243,38	241,54	143117,91
31	661	650	644	236,19	241,51	101578,53
32	755	750	745	242,44	241,49	148509,94
33	785	780	775	244,29	241,47	165296,71
34	755	750	745	242,34	241,46	148473,56
35	625	620	615	240,56	241,45	86112,50
36	755	750	745	242,34	241,45	148492,95
37	719	715	706	238,33	241,45	129533,21
38	730	725	720	245,02	241,42	135200,00
39	744	740	735	243,27	241,40	142672,13
40	781	775	774	245,27	241,22	163028,68

Tabla A.3: Conjunto de Soluciones Factibles para el pozo 3 (LLB0022).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	775	770	765	242,71	245,37	159612,50
2	660	655	650	242,28	245,34	101250,00
3	670	665	660	236,79	245,05	105800,00
4	725	720	715	243,24	245,02	132612,50
5	735	730	725	241,42	245,00	137812,50
6	705	700	695	236,00	244,97	122512,50
7	760	755	750	237,84	244,39	151250,00
8	780	775	770	245,37	244,24	162450,00
9	710	705	700	244,97	243,80	125000,00
10	785	780	775	244,24	243,41	165312,50
11	610	605	600	242,17	243,34	80000,00
12	740	735	730	245,00	243,34	140450,00
13	720	715	710	238,22	243,24	130050,00
14	690	685	680	242,16	242,98	115200,00
15	675	670	665	245,05	242,96	108112,50
16	680	675	670	242,96	242,89	110450,00
17	770	765	760	236,30	242,71	156800,00
18	630	625	620	241,45	242,70	88200,00
19	795	790	785	236,07	242,45	171112,50
20	750	745	740	242,14	242,36	145800,00
21	655	650	645	236,00	242,28	99012,50
22	605	600	0	236,00	242,17	78012,50
23	685	680	675	242,89	242,16	112812,50
24	745	740	735	243,34	242,14	143112,50
25	781	775	770	245,37	241,91	162919,88
26	780	775	770	245,34	241,73	162416,18
27	745	740	735	243,16	241,56	143079,00
28	745	740	735	243,38	241,56	143152,90
29	745	740	735	243,34	241,55	143117,62
30	745	740	735	243,38	241,54	143117,91
31	661	650	644	236,19	241,51	101578,53
32	755	750	745	242,44	241,49	148509,94
33	785	780	775	244,29	241,47	165296,71
34	755	750	745	242,34	241,46	148473,56
35	625	620	615	240,56	241,45	86112,50
36	755	750	745	242,34	241,45	148492,95
37	719	715	706	238,33	241,45	129533,21
38	730	725	720	245,02	241,42	135200,00
39	744	740	735	243,27	241,40	142672,13
40	781	775	774	245,27	241,22	163028,68

Tabla A.4: Conjunto de Soluciones Factibles para el pozo 4 (LLB0026).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	695	690	685	80,16	82,92	193442,00
2	675	670	665	80,64	82,69	181202,00
3	510	505	500	82,12	82,46	95484,50
4	550	544	542	81,94	82,20	113906,03
5	505	500	0	78,00	82,12	93312,00
6	560	555	550	81,88	82,10	118584,50
7	685	680	675	78,53	82,05	187272,00
8	520	515	510	81,57	82,02	99904,50
9	640	635	630	79,63	82,01	160744,50
10	545	540	535	79,41	81,94	111392,00
11	555	550	545	80,74	81,88	116162,00
12	515	510	505	82,46	81,57	97682,00
13	560	555	550	81,94	81,39	118596,04
14	580	575	570	79,65	80,99	128524,50
15	525	520	515	82,00	80,96	102157,61
16	570	565	560	80,30	80,85	123504,50
17	595	590	585	79,37	80,80	136242,00
18	550	545	540	81,94	80,74	113764,50
19	555	550	546	80,74	80,73	116176,29
20	625	620	615	80,62	80,72	152352,00
21	655	650	645	79,44	80,65	169362,00
22	670	665	660	80,44	80,64	178204,50
23	620	615	610	78,31	80,62	149604,50
24	610	605	600	78,86	80,62	144184,50
25	520	515	510	81,69	80,55	99887,00
26	665	660	655	80,25	80,44	175232,00
27	520	515	510	81,59	80,42	99867,67
28	595	590	585	79,38	80,37	136244,31
29	555	550	545	80,82	80,36	116115,13
30	525	520	515	82,02	80,36	102152,00
31	555	550	545	80,75	80,34	116128,88
32	570	565	560	80,34	80,33	123471,07
33	565	560	555	82,10	80,30	121032,00
34	555	550	545	80,72	80,27	116161,81
35	555	550	545	80,75	80,25	116182,78
36	685	680	675	78,55	80,25	187321,23
37	660	655	650	80,65	80,25	172284,50
38	595	590	585	79,36	80,24	136245,64
39	585	580	575	80,99	80,24	131072,00
40	690	685	680	82,05	80,16	190344,50

Tabla A.5: Conjunto de Soluciones Factibles para el pozo 5 (LLB0042).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	640	635	630	347,07	355,86	61250,00
2	670	665	660	349,22	354,79	72200,00
3	630	625	620	347,96	354,73	57800,00
4	645	640	635	355,86	353,98	63012,50
5	610	605	600	350,58	353,36	51200,00
6	612	612	605	353,40	353,20	51802,50
7	630	625	620	348,00	353,04	57796,77
8	630	625	620	347,93	352,96	57776,28
9	630	625	620	347,97	352,94	57801,07
10	675	670	665	354,79	352,87	74112,50
11	575	570	565	344,67	352,84	40612,50
12	640	635	630	347,09	352,78	61248,43
13	515	510	505	352,27	352,34	25312,50
14	510	505	500	346,04	352,27	24200,00
15	625	620	614	347,21	352,02	56261,46
16	695	690	685	346,25	351,96	82012,50
17	605	600	595	346,00	351,64	49620,62
18	605	600	595	346,01	351,63	49622,17
19	670	665	660	348,76	351,04	72210,81
20	650	645	640	353,98	350,68	64800,00
21	605	600	595	346,00	350,58	49612,50
22	530	525	520	348,80	350,46	28800,00
23	615	610	606	353,31	350,35	52668,19
24	550	545	540	343,78	349,91	33800,00
25	675	670	665	354,83	349,85	74112,50
26	660	655	650	348,86	349,75	68450,00
27	595	590	585	349,40	349,69	46493,03
28	675	670	665	355,25	349,60	74101,55
29	595	590	585	349,33	349,55	46545,60
30	590	585	580	347,09	349,38	45000,00
31	615	610	605	353,38	349,26	52777,06
32	665	660	655	349,75	349,22	70312,50
33	540	535	530	347,35	349,05	31250,00
34	595	590	585	349,38	348,92	46512,50
35	575	570	565	344,70	348,87	40635,53
36	655	650	645	350,68	348,86	66612,50
37	615	610	605	353,36	348,86	52812,50
38	525	520	515	345,22	348,80	27612,50
39	565	560	555	345,43	348,62	37812,50
40	549	555	532	343,78	348,49	33417,29

Tabla A.6: Conjunto de Soluciones Factibles para el pozo 6 (LLB0047).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	440	435	430	117,80	144,04	52788,91
2	474	470	462	120,24	135,93	64303,62
3	360	355	350	130,46	133,72	30012,50
4	305	300	0	123,00	133,06	18050,00
5	380	375	370	128,04	132,86	35112,50
6	390	385	380	131,74	132,15	37812,50
7	320	315	310	127,47	131,82	21012,50
8	385	380	375	132,86	131,74	36450,00
9	365	360	355	133,72	131,20	31250,00
10	340	335	330	126,88	131,13	25312,50
11	345	340	335	131,13	130,61	26450,00
12	370	365	360	131,20	130,53	32512,50
13	355	350	345	129,70	130,46	28800,00
14	350	345	340	130,61	129,70	27612,50
15	310	305	300	133,06	129,49	19012,50
16	330	325	320	124,92	128,57	23112,50
17	375	370	365	130,53	128,04	33800,00
18	490	485	480	117,51	127,90	70301,92
19	490	485	480	117,48	127,84	70312,50
20	315	310	305	129,49	127,47	20000,00
21	395	390	385	132,15	127,22	39200,00
22	335	330	325	128,57	126,88	24200,00
23	371	365	363	130,97	126,29	32865,73
24	375	370	365	130,54	126,11	33796,28
25	375	370	365	130,55	126,10	33794,57
26	370	365	360	131,17	125,43	32518,95
27	360	355	350	130,51	125,04	29980,21
28	325	320	315	131,82	124,92	22050,00
29	359	355	348	130,47	124,74	29772,88
30	400	395	390	127,22	124,00	40612,50
31	345	340	335	131,13	123,30	26465,04
32	330	325	320	124,91	123,23	23121,11
33	330	325	320	124,91	123,21	23129,83
34	300	0	0	0,00	123,00	17112,50
35	365	360	355	133,72	122,90	31250,28
36	365	360	355	133,68	122,89	31267,97
37	495	490	485	122,16	122,64	72200,00
38	440	435	430	117,80	122,43	52812,50
39	490	485	480	117,45	122,16	70312,50
40	365	357	353	133,72	122,04	31203,19

Tabla A.7: Conjunto de Soluciones Factibles para el pozo 7 (LLB0050).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1095	1090	1085	497,72	503,01	200344,50
2	1050	1045	1040	494,20	502,96	172872,00
3	950	945	940	498,19	502,82	119072,00
4	960	955	950	495,65	502,76	124002,00
5	990	985	980	493,59	502,63	139392,00
6	995	990	985	502,63	501,89	142044,50
7	1035	1030	1025	497,69	500,96	164164,50
8	1065	1060	1055	499,69	500,07	181804,50
9	965	960	955	502,76	499,79	126504,50
10	925	920	915	497,22	499,69	107184,50
11	1060	1055	1050	499,40	499,69	178802,00
12	1080	1075	1070	497,14	499,62	190962,00
13	905	900	0	493,00	499,52	98124,50
14	1055	1050	1045	502,96	499,40	175824,50
15	1015	1010	1005	497,29	498,94	152904,50
16	910	905	900	499,52	498,50	100352,00
17	945	940	935	496,85	498,19	116644,50
18	980	975	970	497,00	498,08	134162,00
19	1070	1065	1060	500,07	497,79	184832,00
20	935	930	925	494,78	497,78	111864,50
21	1090	1085	1080	497,60	497,72	197192,00
22	1030	1025	1020	494,23	497,69	161312,00
23	950	945	947	498,20	497,66	119258,19
24	1085	1080	1075	499,62	497,60	194064,50
25	915	910	905	498,50	497,39	102604,50
26	965	960	955	502,62	497,38	126527,99
27	910	905	900	499,55	497,32	100352,00
28	965	960	955	502,76	497,31	126492,74
29	965	960	955	502,76	497,31	126547,52
30	910	905	900	499,41	497,31	100352,00
31	1010	1005	1000	496,19	497,29	150152,00
32	965	960	955	502,75	497,25	126459,50
33	920	915	910	497,39	497,22	104882,00
34	1075	1070	1065	497,79	497,14	187884,50
35	975	970	965	495,85	497,00	131584,50
36	925	920	915	497,19	496,95	107216,05
37	920	915	910	497,36	496,92	104869,85
38	925	920	915	497,22	496,87	107116,06
39	940	935	930	497,78	496,85	114242,00
40	1040	1035	1030	500,96	496,84	167042,00

Tabla A.8: Conjunto de Soluciones Factibles para el pozo 8 (LLB0051).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	100	0	0	0,00	63,00	840,50
2	170	165	160	62,44	62,88	6160,50
3	165	160	155	60,77	62,44	5618,00
4	135	130	125	61,12	62,39	2888,00
5	195	190	185	60,65	62,23	9248,00
6	180	175	170	60,14	62,21	7320,50
7	155	150	145	60,66	62,07	4607,36
8	155	150	145	60,72	62,03	4618,02
9	200	195	190	62,23	62,00	9940,50
10	115	110	105	60,19	61,87	1568,00
11	201	195	192	62,22	61,86	10082,79
12	265	260	255	60,89	61,85	21218,00
13	181	176	169	60,14	61,79	7478,30
14	125	120	115	60,42	61,75	2178,00
15	210	205	200	58,86	61,68	11387,42
16	119	115	108	61,88	61,66	1799,67
17	209	204	201	59,06	61,65	11205,46
18	185	180	175	62,21	61,57	7937,59
19	185	180	175	62,17	61,56	7939,82
20	185	180	175	62,18	61,56	7928,24
21	285	280	275	59,99	61,51	25538,00
22	185	180	175	62,16	61,50	7931,65
23	185	180	175	62,21	61,50	7938,00
24	105	100	0	63,00	61,41	1058,00
25	210	205	200	59,06	61,30	11400,50
26	130	125	120	61,75	61,12	2520,50
27	275	270	265	60,64	61,03	23328,00
28	300	295	290	60,87	61,00	29040,50
29	195	190	185	60,54	60,95	9244,75
30	290	285	280	61,55	60,94	26674,53
31	155	150	145	60,68	60,93	4608,00
32	290	285	280	61,51	60,90	26680,50
33	260	255	250	59,91	60,89	20200,50
34	195	190	185	60,61	60,88	9254,04
35	295	290	285	60,90	60,87	27848,00
36	195	190	185	60,65	60,86	9248,07
37	195	190	185	60,65	60,86	9252,11
38	195	190	185	60,70	60,83	9248,00
39	195	190	185	60,73	60,81	9234,68
40	160	155	150	60,93	60,77	5100,50

Tabla A.9: Conjunto de Soluciones Factibles para el pozo 9 (LLB0052).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1930	1920	1910	206,22	214,43	1533000,50
2	1890	1880	1870	207,29	214,41	1463760,50
3	1950	1940	1930	205,47	214,39	1568220,50
4	1820	1810	1800	213,11	214,03	1346440,50
5	1970	1960	1950	209,82	213,14	1603840,50
6	1810	1800	1790	205,00	213,11	1330080,50
7	1710	1700	1690	206,34	213,00	1171980,50
8	1850	1840	1830	205,55	212,94	1396120,50
9	1830	1820	1810	214,03	212,58	1362900,50
10	1620	1610	1600	211,56	211,96	1038240,50
11	1760	1750	1740	209,35	211,93	1249780,50
12	1720	1710	1700	213,00	211,90	1187340,50
13	1610	1600	0	203,00	211,56	1023880,50
14	1820	1810	1800	213,19	211,29	1346407,70
15	1820	1810	1800	213,18	211,29	1346391,60
16	1820	1810	1800	213,13	211,28	1346444,90
17	1820	1810	1800	213,15	211,28	1346303,80
18	1820	1810	1800	213,11	211,27	1346617,60
19	1820	1810	1800	212,97	211,22	1346544,90
20	1870	1860	1850	207,18	211,00	1429740,50
21	1859	1836	1820	205,53	209,94	1411509,60
22	2000	1990	1980	205,99	209,88	1658017,60
23	1790	1780	1770	203,03	209,87	1297683,70
24	1980	1970	1960	213,14	209,86	1621800,50
25	1960	1950	1940	214,39	209,82	1585980,50
26	1750	1740	1730	204,66	209,35	1234020,50
27	1850	1840	1830	205,46	209,20	1396136,00
28	1630	1620	1610	211,96	208,88	1052700,50
29	1910	1900	1890	208,36	208,87	1498180,50
30	1714	1697	1688	206,37	208,77	1177740,10
31	1960	1950	1940	214,39	208,61	1586108,60
32	1650	1640	1630	208,44	208,54	1081920,50
33	1640	1630	1620	208,88	208,44	1067260,50
34	1710	1700	1690	206,29	208,43	1171988,50
35	1710	1700	1690	206,31	208,41	1171936,40
36	1710	1700	1690	206,36	208,40	1172025,50
37	1710	1700	1690	206,43	208,38	1172083,80
38	1900	1890	1880	214,41	208,36	1480920,50
39	1930	1920	1910	206,32	208,17	1532950,60
40	1990	1980	1970	209,83	207,95	1639850,90

Tabla A.10: Conjunto de Soluciones Factibles para el pozo 10 (LLB0053).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	775	770	765	161,28	165,94	189728,00
2	715	710	705	165,04	165,94	154568,00
3	730	725	720	163,27	165,34	163020,50
4	710	705	700	160,24	165,04	151800,50
5	605	600	0	157,00	164,58	99458,00
6	660	655	650	160,28	164,57	125500,50
7	790	785	780	161,52	164,27	199080,50
8	755	750	745	162,75	163,97	177608,00
9	760	755	750	163,97	163,90	180600,50
10	685	680	675	162,85	163,79	138338,00
11	695	690	685	160,49	163,66	143648,00
12	765	760	755	163,90	163,47	183618,00
13	740	735	730	160,84	163,45	168780,50
14	745	740	735	163,45	163,29	171698,00
15	725	720	715	161,23	163,27	160178,00
16	635	630	625	162,15	163,01	113288,00
17	680	675	670	157,31	162,85	135720,50
18	695	690	685	160,50	162,80	143642,18
19	695	690	685	160,47	162,77	143671,74
20	750	745	740	163,29	162,75	174640,50
21	685	680	675	162,87	162,69	138370,28
22	685	680	675	162,88	162,66	138434,82
23	725	720	715	161,18	162,58	160227,92
24	730	725	720	163,14	162,44	163072,26
25	760	756	752	164,03	162,19	180449,30
26	630	625	620	157,78	162,15	110920,50
27	745	740	735	163,42	162,08	171761,27
28	750	745	740	163,26	162,03	174623,63
29	750	745	740	163,32	161,95	174736,72
30	645	640	635	158,96	161,88	118098,00
31	705	699	693	158,94	161,85	149195,42
32	735	730	725	165,27	161,81	165902,73
33	780	775	770	165,94	161,72	192820,50
34	760	755	750	163,93	161,64	180596,51
35	760	755	750	163,97	161,62	180618,12
36	760	755	750	163,98	161,61	180612,86
37	760	755	750	164,06	161,53	180649,77
38	785	780	775	161,72	161,52	195938,00
39	765	760	755	163,87	161,45	183604,31
40	765	760	755	163,90	161,45	183604,66

Tabla A.11: Conjunto de Soluciones Factibles para el pozo 11 (LLB0059).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	345	340	335	271,75	274,88	2888,00
2	390	385	380	272,25	274,87	7320,50
3	375	370	365	273,99	274,77	5618,00
4	315	310	305	271,84	274,75	1058,00
5	485	480	475	273,06	274,69	23328,00
6	445	440	435	272,72	274,24	15488,00
7	335	330	325	273,14	274,23	2178,00
8	465	460	455	272,13	274,09	19208,00
9	370	365	360	271,13	273,99	5100,50
10	425	420	415	272,96	273,81	12168,00
11	495	490	485	271,12	273,73	25538,00
12	330	325	320	272,85	273,14	1860,50
13	480	475	470	270,37	273,06	22260,50
14	420	415	410	270,05	272,96	11400,50
15	325	320	315	270,84	272,85	1568,00
16	440	435	430	271,10	272,72	14620,50
17	380	375	370	274,77	272,54	6160,50
18	348	341	370	271,70	272,45	3101,05
19	410	405	400	272,21	272,45	9940,50
20	470	465	460	274,25	272,45	20198,53
21	470	465	460	274,07	272,44	20200,50
22	465	460	455	272,15	272,44	19203,38
23	420	415	410	270,19	272,39	11399,45
24	420	415	410	270,16	272,39	11404,03
25	420	415	410	270,04	272,39	11396,53
26	420	415	410	270,07	272,39	11398,63
27	420	415	410	270,01	272,39	11399,31
28	390	385	380	272,25	272,33	7323,55
29	390	385	380	272,21	272,33	7316,87
30	408	401	397	270,03	272,32	9694,96
31	305	300	0	270,00	272,32	648,00
32	385	380	375	272,54	272,25	6728,00
33	405	400	395	270,00	272,21	9248,00
34	350	345	340	274,88	272,19	3277,24
35	460	455	450	270,08	272,13	18240,50
36	360	355	350	271,45	272,09	4140,77
37	355	350	345	270,53	271,99	3700,62
38	345	340	335	271,72	271,95	2890,78
39	345	340	335	271,65	271,95	2886,38
40	345	340	335	271,64	271,95	2896,14

Tabla A.12: Conjunto de Soluciones Factibles para el pozo 12 (LLB0060).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1610	1600	0	123,03	311,32	1143072,00
2	1610	1618	0	123,00	304,86	1143072,00
3	1980	1942	1970	123,54	130,24	1771479,20
4	1990	1980	1970	127,65	127,81	1789832,00
5	1860	1850	1840	125,83	127,68	1552322,00
6	1980	1970	1960	126,42	127,65	1770962,00
7	1920	1910	1900	123,41	127,47	1659842,00
8	1950	1940	1930	125,11	127,42	1714952,00
9	1610	1600	0	123,00	127,07	1143072,00
10	1970	1960	1950	123,44	126,86	1752041,10
11	1970	1960	1950	123,53	126,81	1752099,30
12	1810	1800	1790	123,00	126,71	1465472,00
13	1700	1690	1680	124,23	126,63	1283202,00
14	1630	1620	1610	124,02	126,59	1173512,00
15	1970	1960	1950	123,53	126,42	1752192,00
16	1730	1720	1710	124,25	126,36	1331712,00
17	1880	1870	1860	124,73	126,22	1587762,00
18	1730	1720	1710	124,22	126,07	1331756,90
19	1770	1760	1750	123,09	125,97	1397792,00
20	1950	1940	1930	125,13	125,89	1714946,30
21	1700	1690	1680	124,33	125,88	1283197,80
22	1850	1840	1830	125,62	125,83	1534752,00
23	1840	1830	1820	125,07	125,80	1517298,20
24	1840	1830	1820	125,08	125,78	1517257,40
25	1840	1830	1820	125,09	125,62	1517282,00
26	1780	1770	1760	125,97	125,50	1414562,00
27	1850	1840	1830	125,65	125,46	1534564,20
28	1900	1890	1880	125,31	125,46	1623602,00
29	1640	1630	1620	126,59	125,46	1188882,00
30	1980	1970	1960	126,46	125,31	1771004,20
31	1890	1880	1870	126,22	125,31	1605632,00
32	1980	1970	1960	126,48	125,30	1770867,30
33	1670	1660	1650	124,71	125,26	1235592,00
34	1940	1930	1920	124,86	125,11	1696482,00
35	1830	1820	1810	123,57	125,09	1499912,00
36	1740	1730	1720	126,36	124,91	1348025,80
37	1990	1980	1970	127,59	124,88	1789650,40
38	1930	1920	1910	127,47	124,86	1678112,00
39	1930	1920	1910	127,44	124,83	1678228,90
40	1930	1920	1910	127,44	124,82	1678046,40

Tabla A.13: Conjunto de Soluciones Factibles para el pozo 13 (LLB0061).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	410	405	400	314,00	314,94	5100,50
2	435	430	425	312,19	314,78	7938,00
3	415	410	405	314,94	314,57	5618,00
4	315	310	305	313,85	314,46	18,00
5	440	435	430	314,78	314,27	8580,50
6	350	345	340	311,62	314,20	840,50
7	395	390	385	311,17	314,14	3698,00
8	305	300	0	310,00	314,02	8,00
9	405	400	395	310,00	314,00	4608,00
10	310	305	300	314,02	313,85	0,50
11	475	470	465	312,88	313,73	13778,00
12	455	450	445	312,67	313,65	10658,00
13	375	370	365	310,57	313,63	2178,00
14	325	320	315	312,27	313,45	128,00
15	340	335	330	310,59	313,30	480,50
16	415	410	405	314,94	312,91	5608,21
17	415	410	405	314,94	312,91	5601,47
18	415	410	405	314,94	312,91	5612,77
19	415	410	405	314,90	312,90	5618,52
20	470	465	460	310,62	312,88	12960,50
21	440	435	430	314,76	312,82	8575,81
22	450	445	440	310,01	312,67	9940,50
23	475	470	465	312,84	312,61	13792,99
24	310	305	300	314,11	312,61	0,52
25	385	380	375	311,32	312,60	2888,00
26	310	305	300	314,04	312,60	0,58
27	315	310	305	313,86	312,59	18,01
28	480	475	470	313,73	312,55	14620,50
29	438	431	426	312,19	312,46	8257,66
30	460	455	450	313,65	312,44	11400,50
31	490	485	480	311,22	312,43	16380,50
32	322	319	314	312,27	312,37	90,96
33	385	380	375	311,30	312,37	2889,42
34	385	380	375	311,27	312,36	2891,89
35	385	380	375	311,20	312,35	2887,01
36	395	390	385	311,13	312,35	3693,17
37	395	390	385	311,13	312,35	3696,72
38	350	345	340	311,63	312,33	838,99
39	350	345	340	311,63	312,33	839,65
40	360	355	350	310,30	312,32	1300,50

Tabla A.14: Conjunto de Soluciones Factibles para el pozo 14 (LLB0062).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	440	435	430	401,40	403,91	1152,00
2	445	440	435	403,91	403,90	1404,50
3	310	305	300	401,68	403,66	3362,00
4	470	465	460	398,65	402,96	3042,00
5	495	490	485	400,46	402,94	5304,50
6	395	390	385	395,62	402,58	4,50
7	315	310	305	403,66	402,41	2964,50
8	460	455	450	399,10	402,14	2312,00
9	320	315	310	402,41	401,81	2592,00
10	305	300	0	394,00	401,68	3784,50
11	420	415	410	399,44	401,53	392,00
12	460	455	450	399,00	401,49	2311,71
13	460	455	450	399,07	401,48	2310,33
14	425	420	415	401,53	401,46	544,50
15	460	454	450	399,10	401,43	2302,63
16	405	400	395	394,01	401,43	85,68
17	405	400	395	394,00	401,42	85,19
18	435	430	425	396,05	401,40	924,50
19	405	400	395	394,02	401,40	85,93
20	460	455	450	399,11	401,39	2321,97
21	475	470	465	402,96	401,29	3444,50
22	385	380	375	394,36	401,15	24,50
23	470	465	460	398,63	401,12	3030,58
24	470	465	460	398,65	401,06	3041,72
25	470	465	460	398,65	401,05	3042,36
26	470	466	460	398,65	401,03	3052,76
27	470	465	460	398,65	401,03	3047,37
28	405	400	395	394,00	400,92	84,50
29	450	445	440	403,90	400,50	1682,00
30	490	485	480	395,04	400,46	4802,00
31	340	335	330	396,36	399,93	1352,00
32	480	475	470	401,29	399,84	3872,00
33	464	465	446	398,67	399,65	2624,23
34	415	410	405	396,98	399,44	264,50
35	480	475	470	401,27	399,19	3878,36
36	440	435	430	401,39	399,19	1148,10
37	440	435	430	401,43	399,15	1153,11
38	455	450	445	400,50	399,10	1984,50
39	370	365	360	397,24	399,06	242,00
40	315	310	305	403,65	398,99	2957,23

Tabla A.15: Conjunto de Soluciones Factibles para el pozo 15 (LLB0063).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	330	325	320	104,48	104,97	26450,00
2	435	430	425	101,46	104,88	56112,50
3	360	355	350	103,15	104,77	33800,00
4	375	370	365	104,27	104,70	37812,50
5	325	320	315	102,98	104,48	25312,50
6	395	390	385	102,80	104,46	43512,50
7	440	435	430	104,88	104,46	57800,00
8	370	365	360	104,08	104,27	36450,00
9	365	360	355	104,77	104,08	35112,50
10	465	460	455	100,79	103,69	66603,30
11	420	415	410	102,40	103,45	51200,00
12	470	465	460	102,65	103,34	68450,00
13	340	335	330	102,20	103,26	28798,16
14	475	470	465	103,34	103,23	70312,50
15	375	370	365	104,29	103,17	37805,09
16	377	368	366	104,27	103,16	38431,37
17	339	336	329	102,20	103,15	28556,86
18	355	350	345	100,84	103,15	32512,50
19	320	315	310	100,06	102,98	24200,00
20	480	475	470	103,23	102,95	72200,00
21	410	405	400	100,44	102,88	48050,00
22	390	385	380	100,96	102,80	42050,00
23	355	350	345	100,86	102,73	32533,02
24	355	350	345	100,84	102,73	32502,76
25	355	350	345	100,83	102,71	32511,99
26	355	350	345	100,82	102,71	32498,54
27	355	350	345	100,81	102,70	32465,02
28	355	350	345	100,81	102,69	32550,51
29	465	460	455	100,89	102,65	66612,50
30	425	420	415	103,45	102,49	52812,50
31	415	410	405	102,88	102,40	49612,50
32	470	464	460	102,57	102,37	68489,44
33	335	330	325	104,97	102,21	27612,50
34	470	465	460	102,70	102,20	68445,60
35	411	404	401	100,45	102,12	48365,24
36	390	385	380	100,95	102,12	42017,01
37	390	385	380	100,96	102,09	42061,09
38	340	335	330	102,21	102,09	28800,00
39	435	430	425	101,50	101,98	56084,79
40	475	465	459	102,65	101,93	70312,50

Tabla A.16: Conjunto de Soluciones Factibles para el pozo 16 (LLB0064).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	780	775	770	294,56	297,35	124002,00
2	755	750	745	290,80	297,18	111864,50
3	635	630	625	291,97	296,97	62304,50
4	735	730	725	289,49	296,23	102604,50
5	710	705	700	290,99	296,15	91592,00
6	695	690	685	294,86	296,10	85284,50
7	605	600	0	285,00	296,05	52164,50
8	665	660	655	291,13	295,95	73344,50
9	715	710	705	296,15	295,19	93744,50
10	645	640	635	294,08	294,95	65884,50
11	690	685	680	288,27	294,86	83232,00
12	770	765	760	292,32	294,67	119072,00
13	775	770	765	294,67	294,56	121524,50
14	640	635	630	296,97	294,08	64082,00
15	675	670	665	288,58	293,67	77224,50
16	610	605	600	296,05	293,64	53792,00
17	680	675	670	293,67	293,09	79202,00
18	640	635	630	296,89	292,91	64041,65
19	640	635	630	296,84	292,88	64076,67
20	640	635	630	296,93	292,87	64084,54
21	610	605	600	296,04	292,84	53780,85
22	770	765	760	292,31	292,43	119071,07
23	770	765	760	292,33	292,43	119080,67
24	795	790	785	291,82	292,43	131584,50
25	765	760	755	288,04	292,32	116644,50
26	695	690	685	294,96	292,30	85286,25
27	710	705	700	291,17	292,12	91596,02
28	780	775	770	294,55	292,10	123998,68
29	710	705	700	290,95	292,07	91601,25
30	780	775	770	294,59	292,06	123982,50
31	740	735	730	296,23	291,98	104882,00
32	630	625	620	291,54	291,97	60552,00
33	725	720	715	289,20	291,82	98088,26
34	790	785	780	288,83	291,82	129032,00
35	715	710	705	296,12	291,81	93742,95
36	715	710	705	296,11	291,79	93732,84
37	715	710	705	296,16	291,77	93749,95
38	725	720	715	289,16	291,56	98124,50
39	625	620	615	287,18	291,54	58824,50
40	650	645	640	294,95	291,50	67712,00

Tabla A.17: Conjunto de Soluciones Factibles para el pozo 17 (LLB0065).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	510	505	500	143,65	152,85	67344,50
2	560	555	550	149,82	152,81	86944,50
3	640	635	630	149,27	152,71	123504,50
4	685	680	675	144,53	152,19	146882,00
5	670	665	660	149,76	152,03	138864,50
6	550	545	540	144,80	152,00	82824,50
7	515	510	505	152,85	151,79	69192,00
8	525	520	515	147,79	151,78	72962,00
9	650	645	640	144,71	151,27	128524,50
10	695	690	685	143,30	150,36	152352,00
11	620	615	610	145,53	150,35	113764,50
12	555	550	545	152,00	149,82	84872,00
13	665	660	655	149,42	149,76	136242,00
14	590	585	580	143,94	149,74	99904,50
15	630	625	620	145,00	149,55	118584,50
16	660	655	650	147,36	149,42	133644,50
17	635	630	625	149,55	149,27	121032,00
18	540	535	530	146,81	148,87	78804,50
19	675	670	665	152,03	148,86	141512,00
20	685	680	675	144,54	148,46	146845,98
21	685	680	675	144,56	148,45	146908,68
22	605	600	595	143,00	148,00	106722,00
23	650	645	640	144,72	147,94	128567,88
24	650	645	640	144,76	147,94	128538,33
25	650	645	640	144,82	147,93	128508,78
26	520	515	510	151,79	147,79	71064,50
27	605	600	595	143,00	147,60	106755,59
28	605	600	595	143,11	147,58	106730,78
29	655	650	645	151,27	147,36	131072,00
30	620	615	610	145,53	147,36	113774,86
31	670	665	660	149,69	147,10	138870,67
32	580	575	570	144,77	147,09	95392,04
33	580	575	570	144,84	147,08	95460,11
34	580	575	570	144,85	147,07	95487,51
35	670	665	660	149,76	147,07	138873,90
36	580	575	570	144,90	147,06	95504,40
37	670	665	660	149,82	147,05	138855,30
38	550	545	540	144,76	146,92	82858,49
39	535	530	525	144,89	146,81	76832,00
40	640	635	630	149,25	146,80	123499,87

Tabla A.18: Conjunto de Soluciones Factibles para el pozo 18 (LLB0066).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	670	665	660	88,88	91,75	170528,00
2	615	610	605	90,94	91,54	139920,50
3	620	615	610	91,54	91,16	142578,00
4	635	630	625	89,95	91,05	150700,50
5	610	605	600	90,45	90,94	137288,00
6	570	565	560	89,26	90,89	117128,00
7	510	505	500	89,44	90,68	89888,00
8	590	585	580	88,67	90,50	127008,00
9	605	600	595	87,00	90,45	134680,50
10	625	620	615	91,16	90,26	145260,50
11	515	510	505	90,68	90,25	92020,50
12	550	545	540	86,98	90,21	107648,00
13	675	670	665	91,75	90,06	173460,50
14	650	645	640	87,18	89,97	159048,00
15	630	625	620	90,26	89,95	147968,00
16	625	621	615	91,16	89,64	145286,22
17	625	620	615	91,17	89,64	145234,25
18	625	620	615	91,12	89,58	145257,71
19	625	620	615	91,08	89,53	145277,07
20	650	645	640	87,11	89,51	158980,94
21	505	500	0	86,00	89,44	87780,50
22	685	680	675	88,95	89,38	179400,50
23	690	685	680	89,38	89,34	182408,00
24	565	560	555	88,84	89,26	114720,50
25	660	655	650	87,30	89,17	164738,00
26	615	610	605	90,95	89,16	139894,62
27	615	610	605	90,93	89,14	139911,09
28	580	575	570	87,48	89,13	122018,00
29	600	595	590	86,30	89,13	132086,68
30	600	595	590	86,35	89,10	132105,77
31	680	675	670	90,06	88,95	176418,00
32	665	660	655	89,17	88,88	167620,50
33	560	555	550	86,45	88,84	112338,00
34	605	600	595	86,99	88,84	134668,45
35	605	600	595	87,06	88,79	134749,47
36	610	605	600	90,57	88,68	137289,14
37	585	580	575	89,13	88,67	124500,50
38	610	605	600	90,54	88,66	137272,22
39	610	605	600	90,45	88,59	137277,83
40	610	605	600	90,45	88,59	137223,11

Tabla A.19: Conjunto de Soluciones Factibles para el pozo 19 (LLB0067).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	115	110	105	191,00	193,89	2664,50
2	260	255	250	190,79	193,74	2592,00
3	175	170	165	191,37	193,62	84,50
4	185	180	175	189,20	193,58	4,50
5	120	115	110	193,89	193,33	2312,00
6	245	240	235	191,03	193,26	1624,50
7	155	150	145	191,02	193,22	544,50
8	205	200	195	189,00	193,05	144,50
9	190	185	180	193,58	193,03	2,00
10	210	205	200	193,05	192,69	242,00
11	215	210	205	192,69	192,44	364,50
12	260	255	250	190,76	192,39	2593,64
13	135	130	125	190,50	192,38	1404,50
14	290	285	280	191,07	192,36	5202,00
15	105	100	0	189,00	192,35	3444,50
16	145	140	135	191,89	192,22	924,50
17	255	250	245	189,24	192,13	2239,59
18	125	120	115	193,33	192,07	1984,50
19	140	135	130	192,38	191,89	1152,00
20	225	220	215	189,73	191,88	684,50
21	275	270	265	190,33	191,77	3784,50
22	115	110	105	190,95	191,77	2675,33
23	115	110	105	190,96	191,77	2669,77
24	115	110	105	191,06	191,76	2671,84
25	115	110	105	191,01	191,76	2659,08
26	115	110	105	190,97	191,76	2664,32
27	115	110	105	191,04	191,76	2665,87
28	140	135	130	192,38	191,70	1164,87
29	110	105	100	192,40	191,70	3042,00
30	110	105	100	192,36	191,69	3042,00
31	110	105	100	192,45	191,69	3042,00
32	125	120	115	193,34	191,66	1986,54
33	160	155	150	193,24	191,63	392,27
34	160	155	150	193,24	191,62	391,19
35	160	155	150	193,22	191,61	384,55
36	190	185	180	193,67	191,54	2,05
37	225	220	215	189,86	191,52	683,62
38	225	220	215	189,73	191,52	683,82
39	170	165	160	190,78	191,37	162,00
40	195	190	185	193,03	191,12	24,50

Tabla A.20: Conjunto de Soluciones Factibles para el pozo 20 (LLB0069).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	100	0	0	0,00	52,02	1625,70
2	100	0	0	0,05	51,59	1624,77
3	100	0	0	0,06	51,52	1624,50
4	100	0	0	0,00	44,00	1624,50
5	200	195	190	42,94	44,00	12324,50
6	105	100	0	44,00	43,92	1922,00
7	175	170	165	40,02	43,82	8712,00
8	120	115	110	41,45	43,76	2964,50
9	135	130	125	42,42	43,63	4232,00
10	285	280	275	41,09	43,41	29282,00
11	260	255	250	41,35	43,25	23544,50
12	150	145	140	39,48	43,13	5724,50
13	300	295	290	42,17	43,00	33024,50
14	195	190	185	42,21	42,94	11552,00
15	230	225	220	39,90	42,77	17484,50
16	185	180	175	40,51	42,47	10082,00
17	130	125	120	40,14	42,42	3784,50
18	250	245	240	39,13	42,40	21424,50
19	190	185	180	42,47	42,21	10804,50
20	295	290	285	41,33	42,17	31752,00
21	265	260	255	43,25	42,05	24642,00
22	275	270	265	39,86	41,80	26912,00
23	200	195	190	43,00	41,71	12325,42
24	260	255	250	41,28	41,68	23544,72
25	195	190	185	42,16	41,68	11548,49
26	300	295	290	42,11	41,48	32999,62
27	300	295	290	42,21	41,46	33024,50
28	115	110	105	39,43	41,45	2592,00
29	205	200	195	44,00	41,44	13122,00
30	300	295	290	42,31	41,43	33024,50
31	175	170	165	39,97	41,43	8714,17
32	181	184	175	40,53	41,35	9557,13
33	240	235	230	39,44	41,35	19404,50
34	255	250	245	42,40	41,35	22472,00
35	290	285	280	43,41	41,33	30504,50
36	230	225	220	39,90	41,18	17480,99
37	185	180	175	40,51	41,11	10080,02
38	185	180	175	40,50	41,10	10077,24
39	240	235	230	39,56	41,09	19393,79
40	185	180	175	40,52	41,09	10095,78

Tabla A.21: Conjunto de Soluciones Factibles para el pozo 21 (LLB0070).

Número	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	885	880	875	257,31	264,82	200344,50
2	755	750	745	257,76	264,18	126504,50
3	810	805	800	260,15	264,05	155682,00
4	780	780	772	260,86	263,82	139244,89
5	710	705	700	257,81	263,30	104882,00
6	725	720	715	255,13	262,97	111864,50
7	725	720	715	255,13	262,94	111864,50
8	745	740	735	258,69	262,67	121524,50
9	875	870	865	255,74	262,50	194051,05
10	725	720	715	255,13	261,92	111864,50
11	875	870	865	255,85	261,76	194236,69
12	875	870	865	255,74	261,73	194064,50
13	815	810	805	264,05	261,62	158484,50
14	890	885	880	264,82	261,50	203522,00
15	830	825	820	256,18	261,34	167042,00
16	815	810	805	264,03	261,25	158391,34
17	740	735	730	257,96	261,19	119062,63
18	815	810	805	264,12	261,17	158473,62
19	745	740	735	258,71	261,08	121476,77
20	865	860	855	257,81	261,04	187884,50
21	785	780	775	258,16	261,00	142044,50
22	745	740	735	258,70	260,95	121502,73
23	740	735	730	257,92	260,94	119155,67
24	775	770	765	257,30	260,89	136764,50
25	745	740	735	258,65	260,84	121522,56
26	790	785	780	261,00	260,80	144722,00
27	790	785	780	260,88	260,74	144715,47
28	780	775	770	260,88	260,72	139376,48
29	895	890	885	261,50	260,64	206724,50
30	780	775	770	260,87	260,61	139386,59
31	810	805	800	260,18	260,61	155774,36
32	735	730	725	259,50	260,60	116633,59
33	780	775	770	260,90	260,45	139410,52
34	780	775	770	261,08	260,44	139432,66
35	880	875	870	261,75	260,21	197194,08
36	880	875	870	261,74	260,18	197221,69
37	805	800	795	255,00	260,15	152904,50
38	855	850	845	255,97	260,04	181804,50
39	880	875	870	261,80	260,00	197219,46
40	730	725	720	261,92	259,43	114242,00

Tabla A.22: Soluciones Óptimas Seleccionadas.

Pozos	X(k)	X(k-1)	X(k-2)	Y(K-1)	Yn(k)	J
1	1370	1360	1350	172,28	174,30	745420,50
2	715	710	705	169,42	172,99	174050,00
3	775	770	765	242,71	245,37	159612,50
4	695	690	685	80,16	82,92	193442,00
5	670	665	660	349,22	354,79	72200,00
6	440	435	430	117,80	144,04	52788,91
7	1095	1090	1085	497,72	503,01	200344,50
8	100	0	0	0,00	63,00	840,50
9	1930	1920	1910	206,22	214,43	1533000,50
10	775	770	765	161,28	165,94	189728,00
11	345	340	335	271,75	274,88	2888,00
12	1610	1600	0	123,03	311,32	1143072,00
13	410	405	400	314,00	314,94	5100,50
14	440	435	430	401,40	403,91	1152,00
15	330	325	320	104,48	104,97	26450,00
16	780	775	770	294,56	297,35	124002,00
17	510	505	500	143,65	152,85	67344,50
18	670	665	660	88,88	91,75	170528,00
19	115	110	105	191,00	193,89	2664,50
20	100	0	0	0,00	52,02	1625,70
21	885	880	875	257,31	264,82	200344,50

Apéndice B

Código Fuente.

Función que crea las redes neuronales.

```
function [net] = Red(pozo)

%Funcion que crea los modelos neuronales para los pozos.

K=2; %Numero de retrasos en GL
L=1; %Numero de retrasos en BN

%Se organizan los datos por retraso indicado.

[V1,V2]=VectoresRetraso(pozo,K,L);

[V_g1,V_bn] = rndmpair(V1,V2);

q=round(n* .60);

z = n - q;

V1=V_g1; V2=V_bn;
```

```
Entradas = [V1(:, :), V2(:, 2:co2)];

Objetivos = V2(:, 1);

[a, b] = size(Entradas);

[c, d] = size(Objetivos);

Entradas = [V1(:, :), V2(:, 2:co2)];

Objetivos = V2(:, 1);

training_in = Entradas';
training_target = Objetivos';

S1 = 20;
F1 = 'tansig';
S2 = 25;
F2 = 'tansig';

net = newff(training_in, training_target, [S1 S2], {F1 F2}, 'trainlm\');

net.trainparam.lr = 0.01;
net.trainParam.show = 10;
net.trainParam.epochs = 100;
net.trainParam.goal = 1e-2;
net.divideFcn
= ''; net = init(net);

[net, tr] = train(net, training_in, training_target);

Salida = sim(net, training_in)';
```

```
A=training_target;

[g,h]=size(A);

for i = 1:h
    erra(i) = abs((A(i)-Salida(i))/Salida(i));
end

ErrorP = (sum(erra)/h)*100;

errorMSE = (sum(erra)^2)*(1/(2*h));

Corr = corr2(A',Salida);

save POZO.mat net

GraficasPozos(training_in,training_target,Salida,tr,pozo);

end
```

Función que aleatoriza las filas de una matriz.

```
function [A,B]= rndmpair(Matrix1, Matrix2)
% Author: Dr. Istvan S. N. Berkeley,
%         The Artificial Neural Network Analysis Project Lab
%         Philosophy & Cognitive Science,
%         The University of Southwestern Louisiana.
%         (istvan@USL.edu)
%         May 1999
% ----- %

%Check input
```

```
if nargin ~= 2,
disp('ERROR using function rndmpair.')
```

```
    disp('Syntax should be rndmpair(M1, M2).')
```

```
disp('M1 and M2 should be two matrices with the same number of rows.')
```

```
    return
```

```
end
```



```
% Determine the size of matrices
```

```
nOfSamples = size(Matrix1,1);
```

```
% Check that the number of rows agree
```

```
if size(Matrix2,1) ~= nOfSamples,
```

```
    disp('ERROR using function rndmpair.')
```

```
    disp('Matrices must have the same number of rows.')
```

```
    return
```

```
end
```



```
% Set up an index, to ensure that inputs and outputs match
```

```
% N.B. (this is not really needed - it is just for checking purposes).
```

```
Index = [1:nOfSamples]';
```

```
% Set up random number index
```

```
rndIndex = rand(nOfSamples,1);
```

```
% Build first matrix to randomize
```

```
TempM1 = [Index, rndIndex, Matrix1];
```

```
% Build second matrix to randomize
```

```
TempM2 = [Index, rndIndex, Matrix2];
```

```
% Reorder first matrix, according to random numbers
```

```
RawRndM1 = sortrows(TempM1, 2);
```

```
% Reorder second matrix, according to random numbers
```

```
RawRndM2 = sortrows(TempM2, 2);
```

```
% Slice off Index and random info from new version of first matrix
```

```
Matrix1 = RawRndM1(1:end, 3:end);
```

```
% Slice off Index and random info from new version of second matrix
```

```
Matrix2 = RawRndM2(1:end, 3:end);
```

```
% End of matrix order randomization routine
```

```
% ----- %
```

```
A = Matrix1;  
B = Matrix2;}
```

Función que crea los retrasos en las variables.

```
function [matrizR_GL,matrizR_BN] = VectoresRetraso(Vector,K,L)
```

```
g = Vector(:,1);  
b = Vector(:,2);  
[n,m]=size(g);
```

```
matrizR_GL = zeros(n,K); matrizR_BN = zeros(n,L);
```

```
matrizR_GL(:,1) = g; matrizR_BN(:,1) = b; c = 1; for i = 2:K+1  
    matrizR_GL(i:n,i)= g(1:(n-c),1);  
    c = c+1;  
end
```

```
d = 1;
```

```
for i = 2:L+1  
    matrizR_BN(i:n,i)= b(1:(n-d),1);  
    d = d+1;  
end
```

end

Función que genera las gráficas de los modelos neuronales.

```
\textbf{Algoritmo de Ordenamiento No Dominado.} function f =  
non_dominatation_sort_mod(x,M,V)  
  
%Esta funcion ordena la poblacion actual en base al principio de la  
%no-dominancia. Todos los individuos del primer frente tienen jerarquia 1,  
%los del segundo frente tienen jerarquia 2 y asi sucesivamente. Luego que  
%se asignan todos los rangos se calcula el espaciamiento (crowding) para cada frente.  
  
[N, m] = size(x);  
clear m  
front = 1;  
  
F(front).f = []; individual = [];  
  
for i = 1 : N  
  
    % Numero de individuos que dominan al individuo actual.  
    individual(i).n = 0;  
  
    % Individuos que el actual individuo domina.  
    individual(i).p = [];  
  
    for j = 1 : N  
        dom_less = 0;  
        dom_equal = 0;  
        dom_more = 0;
```

```

    for k = 1 : M
        if (x(i,V + k) < x(j,V + k))
            dom_less = dom_less + 1;
        elseif (x(i,V + k) == x(j,V + k))
            dom_equal = dom_equal + 1;
        else
            dom_more = dom_more + 1;
        end
    end
    if dom_less == 0 && dom_equal ~= M
        individual(i).n = individual(i).n + 1;
    elseif dom_more == 0 && dom_equal ~= M
        individual(i).p = [individual(i).p j];
    end
end
if individual(i).n == 0
    x(i,M + V + 1) = 1;
    F(front).f = [F(front).f i];
end
end

while ~isempty(F(front).f)
    Q = [];
    for i = 1 : length(F(front).f)
        if ~isempty(individual(F(front).f(i)).p)
            for j = 1 : length(individual(F(front).f(i)).p)
                individual(individual(F(front).f(i)).p(j)).n = ...
                    individual(individual(F(front).f(i)).p(j)).n - 1;
                if individual(individual(F(front).f(i)).p(j)).n == 0
                    x(individual(F(front).f(i)).p(j),M + V + 1) = ...
                        front + 1;
                    Q = [Q individual(F(front).f(i)).p(j)];
                end
            end
        end
    end
end

```

```
        end
    end
    front = front + 1;
    F(front).f = Q;
end

[temp,index_of_fronts] = sort(x(:,M + V + 1)); for i = 1 :
length(index_of_fronts)
    sorted_based_on_front(i,:) = x(index_of_fronts(i),:);
end current_index = 0; index_order = index_of_fronts;

for front = 1 : (length(F) - 1)
%   objective = [];
    distance = 0;
    y = [];
    previous_index = current_index + 1;
    for i = 1 : length(F(front).f)
        y(i,:) = sorted_based_on_front(current_index + i,:);
    end
    current_index = current_index + i;

    sorted_based_on_objective = [];

    for i = 1 : M
        [sorted_based_on_objective, index_of_objectives] = ...
            sort(y(:,V + i));
        sorted_based_on_objective = [];
        for j = 1 : length(index_of_objectives)
            sorted_based_on_objective(j,:) = y(index_of_objectives(j),:);
        end
        f_max = ...
            sorted_based_on_objective(length(index_of_objectives), V + i);
        f_min = sorted_based_on_objective(1, V + i);
        y(index_of_objectives(length(index_of_objectives)),M + V + 1 + i)...
```

```

        = Inf;
    y(index_of_objectives(1),M + V + 1 + i) = Inf;
    for j = 2 : length(index_of_objectives) - 1
        next_obj = sorted_based_on_objective(j + 1,V + i);
        previous_obj = sorted_based_on_objective(j - 1,V + i);
        if (f_max - f_min == 0)
            y(index_of_objectives(j),M + V + 1 + i) = Inf;
        else
            y(index_of_objectives(j),M + V + 1 + i) = ...
                (next_obj - previous_obj)/(f_max - f_min);
        end
    end
end

distance = [];
distance(:,1) = zeros(length(F(front).f),1);
for i = 1 : M
    distance(:,1) = distance(:,1) + y(:,M + V + 1 + i);
end
y(:,M + V + 2) = distance;
y = y(:,1 : M + V + 2);
z(previous_index:current_index,:) = y;
end f = z();

[n,m]=size(f); z1 = zeros(n,m+1); z1 = f; z1(:,m+1)=index_order; f
= z1;

```

Operadores Genéticos.

```
function f = genetic_operator(parent_chromosome,pozo)
```

```
M=1;
```

```
V=4;

limits = minmax(parent_chromosome');

tour_size = 2;
mu = 20;
mum = 20;

l_limit = limits(:,1); u_limit = limits(:,2);

[N,m] = size(parent_chromosome);

clear m p = 1; pool_size = round(N/2);

was_crossover = 0; was_mutation = 0;

for i = 1 : N

    if rand(1) < 0.1
        child_1 = [];
        child_2 = [];
        % Seleccionando el primer progenitor
        parent_1 = round(N*rand(1));
        if parent_1 < 1
            parent_1 = 1;
        end
        % Seleccionando el segundo progenitor.
        parent_2 = round(N*rand(1));
        if parent_2 < 1
            parent_2 = 1;
        end
        % Verificando que los dos progenitores no son el mismo
        while isequal(parent_chromosome(parent_1,:),parent_chromosome(parent_2,:))
            parent_2 = round(N*rand(1));
        end
    end
end
```

```
    if parent_2 < 1
        parent_2 = 1;
    end
end
end
%Obtener la informacion del cromosoma para cada padre seleccionado
%aleatoriamente.
parent_1 = parent_chromosome(parent_1,:);
parent_2 = parent_chromosome(parent_2,:);

%Aplicar cruce para cada variable de decision en el cromosoma.

for j = 1 : V

    %SBX (Simulated Binary Crossover).
    % Generando numero aleatorio

    u(j) = rand(1);
    if u(j) <= 0.5
        bq(j) = (2*u(j))^(1/(mu+1));
    else
        bq(j) = (1/(2*(1 - u(j))))^(1/(mu+1));
    end

    %Generar el J-esimo elemento del primer hijo

    child_1(j) = ...
        0.5*(((1 + bq(j))*parent_1(j)) + (1 - bq(j))*parent_2(j));

    %Generar el J-esimo elemento del segundo hijo.

    child_2(j) = ...
        0.5*(((1 - bq(j))*parent_1(j)) + (1 + bq(j))*parent_2(j));

    %Estar seguro que el elemento generado esta dentro del
```

```
        %espacio de decision especificado sino se le asigna el
        %extremo.

        if child_1(j) > u_limit(j)
            child_1(j) = u_limit(j);
        elseif child_1(j) < l_limit(j)
            child_1(j) = l_limit(j);
        end
        if child_2(j) > u_limit(j)
            child_2(j) = u_limit(j);
        elseif child_2(j) < l_limit(j)
            child_2(j) = l_limit(j);
        end
    end
end

%Evaluar la funcion objetivo para las descendencia y como antes
%concatenar la el cromosoma de la descendencia con el valor objetivo.

child_1(:,V + 1: M + V) = netEvaluateWells(pozo,child_1');
child_2(:,V + 1: M + V) = netEvaluateWells(pozo,child_2');

%Seleccionar la bandera de cruce. Cuando se aplica cruce se generan
%dos hijos, mientras que cuandos se aplica mutacion se genera un
%solo hijo.

was_crossover = 1;
was_mutation = 0;

else
    %Seleccionar un progenitor aleatorio.
    parent_3 = round(N*rand(1));
    if parent_3 < 1
        parent_3 = 1;
    end
end
```

```
%Obtener la informacion del cromosoma para la seleccion aleatoria
%de los progenitores.
```

```
child_3 = parent_chromosome(parent_3,:);
```

```
%Aplicar mutacion a en cada elemendo del progenitor seleccionado.
```

```
for j = 1 : V
```

```
    r(j) = rand(1);
```

```
    if r(j) < 0.5
```

```
        delta(j) = (2*r(j))^(1/(mum+1)) - 1;
```

```
    else
```

```
        delta(j) = 1 - (2*(1 - r(j)))^(1/(mum+1));
```

```
    end
```

```
%Generar el elemento hijo correspondiente.
```

```
child_3(j) = child_3(j) + delta(j);
```

```
%Estar seguro que el elemento generado esta dentro del espacio
%de decision.
```

```
if child_3(j) > u_limit(j)
```

```
    child_3(j) = u_limit(j);
```

```
elseif child_3(j) < l_limit(j)
```

```
    child_3(j) = l_limit(j);
```

```
end
```

```
end
```

```
%Evaluar la funcion objetivo para cada descendiente y como antes
%concatenar el cromosoma descendiente con el valor objetivo.
```

```
child_3(:,V + 1: M + V) = netEvaluateWells(pozo,child_3(:,1:4)');
```

```
%Cambiar la bandera de mutacion.

was_mutation = 1;
was_crossover = 0;
end

%Mantener la cantidad adecuada y llenar apropiadamente la variable hijo
%con todos los hijos generados para la generacion en curso.

if was_crossover
    child(p,:) = child_1;
    child(p+1,:) = child_2;
    was_crossover = 0;
    p = p + 2;
elseif was_mutation
    child(p,:) = child_3(1,1 : M + V);
    was_mutation = 0;
    p = p + 1;
end
end f = child

function f = replace_chromosome(intermediate_chromosome, M, V,
pop)

[N, m] = size(intermediate_chromosome);

[temp,index] = sort(intermediate_chromosome(:,M + V + 1));

clear temp m

for i = 1 : N
    sorted_chromosome(i,:) = intermediate_chromosome(index(i),:);
```

```
end

max_rank = max(intermediate_chromosome(:,M + V + 1));

previous_index = 0; for i = 1 : max_rank

    current_index = max(find(sorted_chromosome(:,M + V + 1) == i));

    if current_index > pop

        remaining = pop - previous_index;

        temp_pop = ...
            sorted_chromosome(previous_index + 1 : current_index, :);

        [temp_sort,temp_sort_index] = ...
            sort(temp_pop(:, M + V + 2),'descend');

        for j = 1 : remaining
            f(previous_index + j,:) = temp_pop(temp_sort_index(j),:);
        end
        return;
    elseif current_index < pop

        f(previous_index + 1 : current_index, :) = ...
            sorted_chromosome(previous_index + 1 : current_index, :);
    else

        f(previous_index + 1 : current_index, :) = ...
            sorted_chromosome(previous_index + 1 : current_index, :);
        return;
    end

    previous_index = current_index;
```

```
end
```

```
function N = netEvaluateWells(pozo,U)
```

```
tam = 40;
```

```
switch pozo
```

```
    case 1
```

```
        load POZ01.mat
```

```
        for i = 1:tam
```

```
            N(i) = sim(net1,U(:,i));
```

```
        end
```

```
    case 2
```

```
        load POZ02.mat
```

```
        for i = 1:tam
```

```
            N(i) =sim(net2,U(:,i));
```

```
        end
```

```
    case 3
```

```
        load POZ03.mat
```

```
        for i = 1:tam
```

```
            N(i) =sim(net3,U(:,i));
```

```
        end
```

```
    case 4
```

```
        load POZ04.mat
```

```
    for i = 1:tam
        N(i) =sim(net4,U(:,i));
    end

case 5

    load POZ05.mat
    for i = 1:tam
        N(i) =sim(net5,U(:,i));
    end

case 6

    load POZ06.mat

    for i = 1:tam
        N(i) =sim(net6,U(:,i));
    end

case 7

    load POZ07.mat

    for i = 1:tam
        N(i) =sim(net7,U(:,i));
    end

case 8

    load POZ08.mat

    for i = 1:tam
        N(i) =sim(net8,U(:,i));
    end

case 9
```

```
load POZ09.mat

for i = 1:tam
    N(i) =sim(net9,U(:,i));
end

case 10
load POZ010.mat

for i = 1:tam
    N(i) =sim(net10,U(:,i));
end

case 11
load POZ011.mat

for i = 1:tam
    N(i) =sim(net11,U(:,i));
end

case 12
load POZ012.mat

for i = 1:tam
    N(i) =sim(net12,U(:,i));
end

case 13
load POZ013.mat

for i = 1:tam
    N(i) =sim(net13,U(:,i));
end
```

```
case 14
    load POZ014.mat

    for i = 1:tam
        N(i) =sim(net14,U(:,i));
    end

case 15
    load POZ015.mat

    for i = 1:tam
        N(i) =sim(net15,U(:,i));
    end

case 16
    load POZ016.mat

    for i = 1:tam
        N(i) =sim(net16,U(:,i));
    end

case 17
    load POZ017.mat

    for i = 1:tam
        N(i) =sim(net17,U(:,i));
    end

case 18
    load POZ018.mat

    for i = 1:tam
        N(i) =sim(net18,U(:,i));
    end
```

```
case 19
    load POZ019.mat

    for i = 1:tam
        N(i) =sim(net19,U(:,i));
    end

case 20
    load POZ020.mat

    for i = 1:tam
        N(i) =sim(net20,U(:,i));
    end

case 21
    load POZ021.mat

    for i = 1:tam
        N(i) =sim(net21,U(:,i));
    end

case 22
    load POZ022.mat

    for i = 1:tam
        N(i) =sim(net22,U(:,i));
    end
end
```

Función que crea la matriz Q.

```
function VectorQ1 = Qmatrix(chromosome)

[n,m] = size(chromosome); p = 1/n; pond = zeros(n,1); pond(1) = 1;
q = 1;

for i = 2:n
    pond(i,1)= q-p;
    q = q-p;
end

chromosome = [chromosome,pond]; [n,m] = size(chromosome);

pond2 = chromosome(:,m-1:m);

VectorQ1 = zeros(n,1);

for i = 1:n
    VectorQ1(pond2(i,1)) = pond2(i,2);
end

end
```

Función que calcula el error.

```
function Error = calculateError(V,pozo)

ValoresOriginales = fileread('ProduccionActual.txt');
ValoresOriginales = str2num(ValoresOriginales);

T = ValoresOriginales(:,2);
```

```
Error = V - T(pozo);
```

```
end
```

Función que calcula el Índice de Productividad.

```
function J = calculateIndiceP(Q,Error)
```

```
[a,b]=size(Q);
```

```
for i = 1:a
```

```
    J(i) =(0.5)*(Error(i))*(Error(i))*(Q(i));
```

```
end
```

```
J = J';
```

```
end
```