

**DESARROLLO DE UNA METODOLOGÍA PARA LA SIMULACIÓN DEL
COMPORTAMIENTO DE PRODUCCIÓN DE UN YACIMIENTO
USANDO REDES NEURONALES**

SALVADOR RUZ ROJAS

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE CIENCIAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS
BUCARAMANGA**

2007

**DESARROLLO DE UNA METODOLOGÍA PARA LA SIMULACIÓN DEL
COMPORTAMIENTO DE PRODUCCIÓN DE UN YACIMIENTO
USANDO REDES NEURONALES**

**AUTOR:
ING. SALVADOR RUZ ROJAS**

TRABAJO DE INVESTIGACIÓN

**DIRECTORA:
DRA. ZULY HIMELDA CALDERÓN CARRILLO**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE CIENCIAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS
BUCARAMANGA**

2007

DEDICATORIA

A mi esposa Karen y a mi hijo Manuel Salvador, quienes forjan mi verdadera felicidad y quienes fueron los que pagaron la cuota más alta de amor y tiempo compartido, para que yo pudiera llevar a buen término éste trabajo de investigación.

A mis padres María Mercy y Manuel Salvador, de quienes aprendí que hay que tener los pies firmes en la tierra, sobre todo cuando se necesitan bien fuertes para saltar muy alto y emprender el vuelo.

A mis hermanas Gina Mercy y Alejandra, con quienes he forjado el fuerte amor que se construye a punta de eso que el juglar pregona como los “ratos solemnes y otros de agonía”.

A mi tía Anita, quien me brindó su apoyo y confianza en un momento oportuno y muy a pesar de todo.

A la señora Carmen Luna, quien me acompañaba y me daba aliento cuando las noches magangueleñas se me hacían cada vez más oscuras.

A mis amigos de infancia y los de ahora... aquellos de para siempre.

A aquellos que más que mis amigos, son mis camaradas.

AGRADECIMIENTOS

La culminación exitosa de éste trabajo se la debo a muchas personas que me prestaron su apoyo, desde el día en que terminé mis estudios de pregrado hasta el momento en que escribo estas líneas. A todos expreso mi gratitud, pero en particular quisiera destacar el respaldo de:

Carlos Humberto Amaya, por ser el primero en tenderme la mano para reincorporarme a mi profesión.

Néstor Fernando Saavedra, por haberme planteado la opción de vincularme al grupo de investigación a través del cual inicié mis estudios de maestría.

Zuly H. Calderón, por acompañarme y orientarme en este trabajo de investigación.

Alberto Mendoza Rojas, por su apoyo incondicional en el proceso de continuar mi formación académica y profesional.

Fernando Calvete González y Héctor Niño Quiñónez, por su colaboración en la revisión y aceptación de este trabajo de investigación.

CONTENIDO

	Pág.
INTRODUCCIÓN	15
1. REDES NEURONALES DE ALIMENTACIÓN HACIA ADELANTE Y ENTRENAMIENTO CON PROPAGACIÓN DEL ERROR HACIA ATRÁS	19
1.1. REDES NEURONALES DE ALIMENTACIÓN HACIA DELANTE	27
1.2. ALGORITMO BACKPROPAGATION	34
2. ELEMENTOS BÁSICOS DEL FLUJO EN POZOS PETROLÍFEROS	50
2.1. DECLINACIÓN DE PRODUCCIÓN EN POZOS PETROLÍFEROS	50
2.2. ECUACIÓN DE FLUJO A ESTADO SEUDO-ESTABLE	60
2.3. CURVA IPR	67
2.4. INFLUENCIAS ENTRE POZOS	69
3. MODELO SUSTITUTO INTELIGENTE EN REDES NEURONALES PARA LA SIMULACIÓN DE YACIMIENTOS	74
3.1. ANÁLISIS INDIVIDUAL DE POZOS CON RNA	76
3.2. ANÁLISIS DE MÚLTIPLES POZOS CON RNA	81
4. HEURÍSTICA PARA EL USO DE UN SIRMANN.....	87
4.1. SELECCIÓN DEL SOFTWARE.....	87
4.2. FILTRADO Y ORGANIZACIÓN DE LOS DATOS	88
4.3. DEFINICIÓN DE VARIABLES	91
4.4. CONSTRUCCIÓN DEL SIRMANN.....	92
4.5. ESCALAMIENTO.....	96
5. EVALUACIÓN DE DIFERENTES ESQUEMAS DE SIRMANN	104
5.1. CRITERIO DE VALORACIÓN DE LOS RESULTADOS DE LA RNA.....	105
5.2. ESQUEMA RNA PARA UN SOLO POZO	109
5.2.1. DECLINACIÓN SIMPLE	109
5.2.2. DECLINACIÓN CON DIVISIÓN DE DÍAS Y VOLUMEN	117
5.2.3. DECLINACIÓN CON PRESIÓN DE FONDO	121
5.2.4. DECLINACIÓN CON PRESIÓN DE FONDO Y CAUDALES EN LAS ENTRADAS.....	130
5.2.5. ESQUEMA GENERAL PARA UN SOLO POZO.....	132
5.3. ESQUEMA RNA PARA VARIOS POZOS	136
5.3.1. SIRMANN TIPO I.....	137

5.3.2.	SIRMANN TIPO II.....	139
5.3.3.	SIRMANN TIPO III.....	141
5.3.4.	SIRMANN TIPO IV	147
6.	METODOLOGÍA PARA EMULAR LA PRODUCCIÓN EN UN CAMPO PETROLÍFERO CON REDES NEURONALES ARTIFICIALES.....	152
6.1.	ASPECTOS GENERALES	152
6.2.	MODELAMIENTO DE UN SOLO POZO	153
6.3.	MODELAMIENTO DE VARIOS POZOS	154
7.	CONCLUSIONES Y RECOMENDACIONES	155

LISTA DE TABLAS

	Pág.
Tabla 1. Tabla de verdad del XOR.....	45
Tabla 2. Datos de producción para el ejemplo exponencial*	55
Tabla 3. Datos de producción para el ejemplo hiperbólico*	57
Tabla 4. Campos y comentarios del filtrado general.	89
Tabla 5. Encabezados del pozo.....	89
Tabla 6. Campos del reporte de producción o inyección.	90
Tabla 7. Campos del reporte de presiones.	90
Tabla 8. Prefijos para la definición de variables.....	91
Tabla 9. Ejemplo de definición de variables de entrada y salida.	93
Tabla 10 (a). Datos iniciales del ejemplo de selección del tiempo disponible.	95
Tabla 11. Ejemplo de evaluación de dos escenarios.	96
Tabla 12(a). Valores de <i>A</i> y <i>B</i> de la tabla 11.	98
Tabla 13. Datos utilizados para trazar la figura 55.....	107
Tabla 14 a. Declinación Simple en TRAINBR, pozo VAV-01.....	109
Tabla 15(a). Declinación Simple en TRAINBR, pozo VAV-02.	112
Tabla 16(a). Declinación Simple en TRAINBR, pozo MAN-04.....	114
Tabla 17(a). Declinación tipo II en TRAINBR, pozo MAN-03.....	117
Tabla 18(a). Declinación tipo II en TRAINBR, pozo MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).....	119
Tabla 19(a). Declinación tipo III en TRAINBR, pozo MAN-03.....	122
Tabla 20(a). Declinación tipo III en TRAINBR, pozo VAV-01.....	126
Tabla 21(a). Declinación tipo III en TRAINBR, pozo MAN-07.....	129
Tabla 22(a). Declinación tipo V en TRAINBR, pozo VAV-01.	132
Tabla 23(a). SIRMANN tipo I en TRAINBR.....	138
Tabla 24(a). SIRMANN tipo II en TRAINBR.....	140

LISTA DE FIGURAS

	Pág.
Figura 1. Funciones de activación.	21
Figura 2. Clasificación de patrones.....	23
Figura 3. Agrupamiento.	23
Figura 4. Aproximación de funciones.....	24
Figura 5. Predicciones.	25
Figura 6. Problema del agente viajero.	26
Figura 7. Memoria de contenido direccionable.	26
Figura 8. Respuesta a un mecanismo de control.....	27
Figura 9. Estructura Feedforward.	28
Figura 10. Estructura de una neurona.	28
Figura 11. Estructura de la neurona modificada.	29
Figura 12. Estructura simplificada de la neurona.....	30
Figura 13. Estructura de una capa.....	30
Figura 14. Funciones de activación derivables.	32
Figura 15. Ejemplo de estructura feedforward.	33
Figura 16. Flujo de datos en la red feedforward.....	34
Figura 17. Esquema del algoritmo backpropagation.....	42
Figura 18. Nuevo resultado después de hacer una iteración backpropagation.	44
Figura 19. Punto de partida para la solución del XOR con una RNA.....	46
Figura 20. Solución encontrada con una RNA para el problema del XOR.....	46
Figura 21. Avance del error con respecto a las épocas.	48
Figura 22. Ejemplo de declinación exponencial.....	56
Figura 23. Ejemplo de declinación hiperbólica.....	58
Figura 24. Ilustración del método utilizado por Darcy para desarrollar su ecuación de flujo.	61
Figura 25. Esquema de flujo yacimiento-pozo.	63

Figura 26. Esquema de flujo radial.	65
Figura 27. Caída de presión por factor de daño.....	67
Figura 28. Ejemplo de IPR.....	69
Figura 29. Perfil de presión en cartesiano.	70
Figura 30. Perfil de presión en matices de colores.	71
Figura 31. Perfil de presión en forma de superficie.....	71
Figura 32. Superposición de perfiles de presión en modo superficie.....	72
Figura 33. Delimitación de áreas de drenaje.	72
Figura 34. Declinación con RNA tipo I. Forma más simple.....	77
Figura 35. Declinación con RNA tipo II.	78
Figura 36. Declinación con RNA tipo III.	78
Figura 37. Declinación con RNA tipo IV.....	79
Figura 38. Esquema general de RNA para un solo pozo en análisis.....	80
Figura 39. Etapas de la descripción del yacimiento.	81
Figura 40. Yacimiento dividido en bloques para simulación numérica.....	82
Figura 41. Comparación de modelos de descripción del yacimiento.	83
Figura 42. Modelo SIRMANN tipo I.....	84
Figura 43. Modelo SIRMANN tipo II.....	84
Figura 44. Modelo SIRMANN tipo III.....	85
Figura 45. Modelo SIRMANN tipo IV.	86
Figura 46. Esquema general de tablas.	88
Figura 47. Definición de la RNA con Matlab.	93
Figura 48. Entrenamiento y simulación de la RNA con Matlab.	94
Figura 49. Escalamiento.	97
Figura 50. Formato de configuración de la RNA.....	99
Figura 51. Estructura de RNA utilizada en el ejemplo del escalamiento.....	99
Figura 52 (a). Ejemplo de escalamiento con Regularización Bayesiana.	100
Figura 53. Ejemplo de escalamiento con Gradiente y Momentum.....	100
Figura 54(a). Ejemplo de escalamiento con Levenberg-Marquardt (aceite).	101

Figura 55. Inconsistencias del r-cuadrado como evaluador de regresiones.	106
Figura 56. Factores de ajuste para los datos de la tabla 13.	108
Figura 57. Declinación Simple, TRAINBR, configuración 1:4:5:1, VAV-01.	110
Figura 58. Declinación Simple, TRAINGDA, configuración 1:4:1, pozo VAV-01..	111
Figura 59. Declinación Simple, TRAINLM, configuración 1:2:1, pozo VAV-01. ...	111
Figura 60. Declinación Simple, TRAINBR, configuración 1:2:1, VAV-02.	113
Figura 61. Declinación Simple, TRAINGDA, configuración 1:2:1, pozo VAV-02..	113
Figura 62. Declinación Simple, TRAINLM, configuración 1:2:1, pozo VAV-02. ...	114
Figura 63. Declinación Simple, TRAINBR, configuración 1:2:2:1, MAN-04.	115
Figura 64. Declinación Simple, TRAINGDA, configuración 1:4:5:1, MAN-04.....	115
Figura 65. Declinación Simple, TRAINLM, configuración 1:2:2:1, MAN-04.	116
Figura 66. Declinación Simple, TRAINBR, configuración 1:4:1, MAN-04.	116
Figura 67. Declinación tipo II, TRAINBR, configuración 2:2:1, MAN-03.....	118
Figura 68. Declinación tipo II, TRAINLM, configuración 2:4:1, MAN-03.....	118
Figura 69. Declinación tipo II, TRAINLM, configuración 2:4:5:1, MAN-03.....	119
Figura 70. Declinación tipo II, TRAINBR, configuración 2:4:1, MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).....	120
Figura 71. Declinación tipo II, TRAINLM, configuración 2:4:1, MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).....	120
Figura 72. Conjuntos de presión de fondo para evaluar la declinación tipo III.....	122
Figura 73(a). Declinación tipo III, TRAINBR, 3:4:3, MAN-03, aceite.....	123
Figura 74(a). Declinación tipo III, TRAINLM, 3:4:5:3, MAN-03, aceite.....	124
Figura 75(a). Declinación tipo III, TRAINBR, 3:4:1, VAV-01.....	126
Figura 76(a). IPR por declinación tipo III, TRAINBR, VAV-01, 01-Dic-2003.	127
Figura 77(a). IPR por declinación tipo III, TRAINLM, VAV-01, 01-Dic-2003.	128
Figura 78(a). Declinación tipo III, TRAINBR, 3:2:2:1, MAN-07.	129
Figura 79. Escenarios evaluados en VAV-03.	131
Figura 80(a). Declinación tipo IV, TRAINBR, VAV-03.....	131
Figura 81(a). Declinación tipo V, TRAINBR, 4:4:1, VAV-01.....	133

Figura 82(a). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Dic-2003.....	133
Figura 83(a). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Dic-2003.....	134
Figura 84(a). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Dic-2003. (Sumando puntos IPR según Vogel).....	135
Figura 85(a). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Dic-2003. (Sumando puntos IPR según Vogel).....	136
Figura 86(a). SIRMANN tipo I, TRAINBR, 7:4:3, MAN-03.	139
Figura 87(a). SIRMANN tipo II, TRAINBR, 8:4:2, MAN-03.	140
Figura 88. Kriging para permeabilidad y porosidad, campo Manguitos.	142
Figura 89(a). SIRMANN tipo III, TRAINBR, 3:4:2, permeabilidad en cartesiano..	143
Figura 90(a). SIRMANN tipo III, TRAINLM, 3:4:5:2, permeabilidad en cartesiano.	144
Figura 91(a). SIRMANN tipo III, TRAINBR, 3:4:2, permeabilidad en contornos. .	145
Figura 92(a). SIRMANN tipo III, TRAINLM, 3:4:5:2, permeabilidad en contornos.	146
Figura 93. Potencial esperado en el campo Yatí por Kriging.	147
Figura 94. Potencial de producción en Kriging y según entrenamiento Levenberg- Marquardt, estructura 5:4:1 (campo Yatí).	148
Figura 95. Potencial de producción en BR 5:4:5:1 y LM 5:2:1 (campo Yatí).....	148
Figura 96(a). Potencial de producción en LM 3:2:1 y LM 3:2:2:1 (campo Yatí). ..	149
Figura 97(a). Potencial de producción en LM 2:2:1 y LM 2:2:2:1 (campo Yatí). ..	150
Figura 98. Potencial de producción en BR 2:2:1 y BR 2:4:1 (campo Yatí).....	151

TÍTULO: DESARROLLO DE UNA METODOLOGÍA PARA LA SIMULACIÓN DEL COMPORTAMIENTO DE PRODUCCIÓN DE UN YACIMIENTO USANDO REDES NEURONALES

AUTOR: RUZ ROJAS, Salvador **

PALABRAS CLAVE: redes neuronales artificiales, simulación, yacimientos, producción, declinación, matlab, delphi.

CONTENIDO:

En la industria del petróleo, toda vez que se quiere evaluar la respuesta de un campo a diferentes condiciones de operación, se utiliza preferiblemente la simulación numérica. Ésta estrategia, a pesar de tener un relativo éxito, presenta algunos costos y limitantes que pueden llegar a ser superados con la ayuda de mecanismos alternativos de simulación.

Con el objetivo de construir un modelo sustituto, capaz de emular el comportamiento de producción de un campo, se hizo un estudio para determinar la metodología a seguir para que una red neuronal artificial (RNA) capturara los elementos necesarios para hacer los estimativos de producción de aceite bajo diferentes escenarios.

La investigación se inició con una revisión detallada de los fundamentos de las RNA de alimentación hacia delante y retropropagación del error (parte codificada en Delphi®).

Luego, se abordaron los elementos propios del flujo de fluido en medios porosos, como etapa previa a la definición de las variables que deberían ser tenidas en cuenta para las entradas y las salidas de las RNAs.

Los modelos de RNAs fueron planteados desde el más simple (un solo pozo) hasta el más complejo (varios pozos actuando de manera simultánea), y las variables escogidas fueron discriminadas por su comportamiento dinámico o estático, según el escenario de simulación.

Cada modelo propuesto fue evaluado por medio de una aplicación construida en Matlab®. Los datos utilizados para el entrenamiento y la simulación de las RNAs, fueron obtenidos de casos reales de campos colombianos y de la simulación numérica de un campo ficticio. Éste último se creó para obtener datos de aquellos escenarios que no pueden ser reproducidos en la realidad por cuestiones económicas.

Finalmente, se hizo un resumen de las estructuras de redes, las variables y los procedimientos que garantizaron un acercamiento de las RNAs entrenadas, al comportamiento esperado.

* Trabajo de Investigación.

** Escuela de Ingeniería de Sistemas. Maestría en Informática y Ciencias de la Computación.

Directora: ZULY H. CALDERÓN CARRILLO.

® Delphi es una marca registrada de Borland Software Corporation.

® Matlab es una marca registrada de The MathWorks Inc.

TITLE: DEVELOPMENT OF A METHODOLOGY TO SIMULATE OIL RESERVOIR PRODUCTION DATA USING ARTIFICIAL NEURAL NETWORKS^{*}

AUTHOR: RUZ ROJAS, Salvador^{}**

KEY WORDS: artificial neural networks, reservoir simulation, oil rate declining, matlab, delphi.

SUMMARY:

In the oil industry, it is a common practice to use numerical simulation to evaluate the reservoir behavior under different operation scenarios. Instead of its success, numerical reservoir simulation has some drawbacks (like cost, history matching delay, among others) that can be solved using alternative tools.

This research project was performed with the aim of finding a surrogate model to capture the relationships that lead the oil rate behavior in an oilfield. To reach this objective the literature review started with the essentials of feed-forward back-propagation neural networks (this code was written in Delphi[™] language).

The second part of the theory review was focused on the fundamentals of oil well performance, in order to select the variables that should be taken into account for the artificial neural networks (ANN) inputs and outputs.

Several ANN models were considered, from the simplest one (an oil well with one input and output) to the more complex one (several wells acting at the same time). In addition, each variable was categorized accordingly to its steady or dynamic nature.

Each proposed model was tested using an application built in Matlab[™] code. The data used in the training and the simulation were taken from both, actual production reports and a numerical simulation performed for a fictitious oilfield. This last one because of some scenarios can not be performed in the reality due to economical and operational reasons.

By comparing the results of the models with the expected values, best ANN, recommended practices and suggested variables were sorted out and summarized.

At the end of this research, it was found out that some physical constrains have to be added to the data to improve the training. Unfortunately, sometimes these constrains are the questions that need to be solved, so the methodology, in some cases, may be inadequate.

* Research Project.

** Systems Engineering School. Master at Informatics and Computer Sciences.

Director: ZULY H. CALDERÓN CARRILLO.

[™] Delphi is a trade mark of Borland Software Corporation.

[™] Matlab is a trade mark of The MathWorks Inc.

INTRODUCCIÓN

La administración acertada de un yacimiento petrolífero, entendida como la estrategia para obtener el mayor beneficio económico a partir de la explotación, tiene su principal soporte en el entendimiento del sistema de flujo que determina la capacidad de extracción de crudo desde el subsuelo hasta la superficie.

Un conocimiento del comportamiento del campo es la clave para tomar las mejores decisiones. Sin embargo, los modelos matemáticos de flujo no siempre son fáciles de obtener y en algunos casos no se ajustan a la realidad.

Actualmente se puede, partir de datos de geología y de fluidos, simular numéricamente la respuesta del campo a diferentes condiciones de presiones en fondo. Esto se logra siguiendo modelos de ecuaciones diferenciales y haciendo ajustes con datos reportados de producción.

La desventaja de éste enfoque está en que no siempre se tiene información confiable y por lo tanto, los resultados obtenidos pueden estar alejados de la realidad. Adicionalmente, el costo de la simulación puede ser muy alto, en términos de tiempo y dinero, para los presupuestos que se manejan en campo.

En éste documento, se presentan los resultados obtenidos al final de una investigación que consistía en procurar la representación del comportamiento de producción de un campo petrolífero, a partir del uso de redes neuronales. La idea principal consistió en invertir el proceso de análisis, utilizando los datos de producción para construir y no simplemente para ajustar los modelos iniciales. Para ello, se optó por las redes neuronales artificiales por ser muy útiles en la emulación de sistemas con características no lineales.

Ésta nueva perspectiva, denominada por algunos como modelos sustitutos inteligentes, ya ha sido expuesta por varios autores, entre ellos se encuentran Boomer¹, Centilmen, Ertekin y Grader², y Panda y Chopra³. Sin embargo, aún existía la necesidad de hacer una revisión más amplia y exhaustiva acerca de los fundamentos computacionales y de la ingeniería de petróleos, que definen aspectos tales como la selección de variables de entrada y salida, la estructura de los modelos, los tipos de entrenamiento a utilizar, la validez de los resultados, el grado de confianza de las respuestas de la red, entre otros.

El problema fue abordado desde los casos particulares hasta la perspectiva general. En otras palabras, se comenzó con el análisis individual de los pozos hasta llegar a la revisión de todo el campo.

Analizando un solo pozo, se definieron las variables más relevantes, el manejo previo que se debía dar a los datos de entrenamiento, el tipo de red más favorable y la manera de ajustar el modelo al comportamiento real que se esperaba.

Para el caso general de producción de todo el campo, fue necesario simular numéricamente un campo ficticio, para poder hacer una evaluación objetiva de los resultados obtenidos con la red. Sólo de ésta manera se podían notar dos situaciones que se querían resaltar: el efecto de la no-linealidad en los resultados y la interferencia entre pozos.

Las redes escogidas para la simulación fueron las de tipo **feedforward** con entrenamiento **backpropagation**. Inicialmente se programó la versión más simple de **backpropagation** en Delphi Borland, pero dado que los resultados se

¹ BOOMER, Robert J. Predicting production using a neural network (artificial intelligence beats human intelligence). En: Society of Petroleum Engineers (June 1995). SPE 30202.

² CENTILMEN, A.; ERTEKIN, T., and GRADER, A. S. Applications of neural networks in multiwell field development. En: Society of Petroleum Engineers (October 1999). SPE 56433.

³ PANDA, M. N., and CHOPRA, A. K. An integrated approach to estimate well interactions. En: Society of Petroleum Engineers (February 1998). SPE 39563.

encontraban muy limitados, se optó por la herramienta de redes neuronales que ofrece Matlab. Éste software es más ventajoso porque contiene algunas modificaciones a la función de error, que hace que los resultados de la red entrenada sean más consistentes con la respuesta esperada.

En Matlab se construyó el código para la selección de variables, el pre-procesamiento de los datos, la inclusión de restricciones y la validación de la respuesta de la red. Éste software, que es parte de los resultados del proceso investigativo, es una herramienta que opera como un laboratorio de modelos, en donde se pueden evaluar diferentes propuestas de estructuras de red, para la emulación del comportamiento de producción de un yacimiento o un pozo petrolífero en particular.

En resumen, el aporte que se logra con éste trabajo investigativo, además de las herramientas software construidas en Delphi y en Matlab, es:

- La definición y validación de diferentes modelos de redes para la emulación del comportamiento de producción de un yacimiento. Desde el modelo más sencillo, hasta el más elaborado.
- La incorporación, en el entrenamiento de la red, de elementos físicos propios del sistema a simular.
- La síntesis y evaluación de la heurística que rige el uso de redes neuronales, en problemas básicos de la industria del petróleo.

Antes de presentar, en éste documento, los modelos a evaluar y resultados obtenidos, se dedican dos capítulos para explicar los fundamentos de las ciencias de la computación y de la ingeniería de petróleos, necesarios para el entendimiento de las hipótesis planteadas y la validación de las mismas.

En el primer capítulo se abordan las redes neuronales de tipo **feedforward** en entrenamiento **backpropagation**. Aunque esta explicación puede encontrarse en diferentes textos de sistemas, se decidió incluir en éste documento como una alternativa sencilla, escrita en español y con ejemplos, para aquellos que quieran encontrar en un solo texto, todos los elementos básicos para construir y entrenar éste tipo de redes neuronales artificiales.

En el segundo capítulo se resumen los fundamentos del flujo de fluidos en medios porosos, que deben ser conocidos antes de escoger las variables y las estructuras de las redes a evaluar.

En el tercer capítulo se plantean múltiples modelos de redes, de acuerdo con lo explicado en el capítulo uno e integrando los diferentes tipos de variables expuestos en el capítulo dos.

En el capítulo cuatro se deja una lista de algunas recomendaciones previas a la construcción y uso de los modelos de red propuestos. Mientras que en el capítulo cinco se presentan los resultados obtenidos de la evaluación de los modelos propuestos en el capítulo tres.

Finalmente, en los capítulos seis y siete se compilan las conclusiones y recomendaciones logradas después de todo el proceso investigativo. Allí se tienen algunas pautas que son generales para todas las redes neuronales y que posiblemente han sido resueltas con anterioridad por otros autores, pero también se encuentran puntos que orientan de manera más clara y concisa el uso de redes neuronales en la industria del petróleo.

1. REDES NEURONALES DE ALIMENTACIÓN HACIA ADELANTE Y ENTRENAMIENTO CON PROPAGACIÓN DEL ERROR HACIA ATRÁS

El interés inicial⁴ en las redes neuronales artificiales (RNA), también conocidas como modelos conexionistas, comenzó después de la introducción de unos modelos simplificados de neuronas presentados por McCulloch y Pitts⁵ en 1943. Estas neuronas artificiales fueron presentadas como modelos de neuronas biológicas y como componentes conceptuales para circuitos que pueden desempeñar tareas computacionales.

En 1969, después de que Minsky y Papert⁶ demostraran las deficiencias de los modelos de perceptrones, el interés de los inversionistas y de los investigadores tomó otra dirección diferente a la de las RNA. Sólo pocos investigadores continuaron con sus esfuerzos, los más notables fueron Teuvo Kohonen, Stephen Grossberg, James Naderson, y Kunihiro Fukushima (referencias para estos autores pueden encontrarse en Kröse y van der Smagt⁷).

La investigación en RNA reapareció sólo después de que algunos avances teóricos y tecnológicos fueron logrados a principios de los años ochentas. En el aspecto teórico, el avance más notable fue el descubrimiento del algoritmo de retro-propagación del error (**backpropagation**); mientras que en el ámbito tecnológico los adelantos se encontraban en la mayor capacidad de procesamiento del nuevo hardware.

⁴ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 13-15.

⁵ MCCULLOCH, W. S., and PITTS, W. A logical calculus of the ideas immanent in nervous activity. En: Bulletin of Mathematical Biophysics. Vol. 5. p. 115-133. Citado por: ver referencia 4.

⁶ MINSKY, M., and PAPERT, S. Perceptrons: an introduction to computational geometry. The MIT Press, 1969. Citado por: ver referencia 4.

⁷ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 123-130.

Las redes neuronales artificiales pueden ser caracterizadas de mejor manera como “modelos computacionales” con propiedades particulares como la habilidad para adaptarse o aprender, generalizar, agrupar u organizar datos, y para operaciones basadas en procesamiento en paralelo. Sin embargo, estas características pueden ser adjudicadas a algunos de los modelos (no neuronales) ya existentes.

Los aspectos generales que distinguen un modelo de distribución paralela son: un conjunto de unidades de procesamiento (neuronas, celdas), un estado de activación para cada unidad con su correspondiente salida, conexiones entre unidades (generalmente definidas por pesos), una regla de propagación, una función de activación, una señal de desviación para cada unidad y un método de agrupamiento de la información (regla de aprendizaje).

Las unidades de procesamiento desempeñan un trabajo relativamente simple, reciben la entrada de sus vecinos o de fuentes externas y la utilizan para calcular la señal de salida que se propaga a las otras unidades. El sistema es inherentemente paralelo en el sentido de que muchas unidades pueden ejecutar sus tareas al mismo tiempo.

En algunos casos se asume que cada unidad provee una contribución a la entrada de la unidad a la cual está conectada. El total de entradas a una unidad es simplemente la suma ponderada (por los pesos) de todas las salidas de las unidades que están conectadas, sumadas a un término de desviación.

La función de activación es una regla que da el efecto total de la señal de entrada en la activación de la unidad. La función debe tomar el total de las entradas y la actual desviación, y producir un nuevo valor de activación de la unidad⁸.

⁸ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 17.

Estas funciones pueden ser de tipo umbral, semilineal, sigmoidea y estocástica (ver figura 1).

Figura 1. Funciones de activación.



FUENTE: "An Introduction to Neural Networks". Ben Kröse and Patrick van der Smagt. University of Amsterdam. 1996.

En los casos de la función de activación estocástica, la activación no se halla de manera determinística de acuerdo con la señal de entrada, sino que se define como la probabilidad de que una neurona tenga un alto valor de activación según su señal de entrada.

De acuerdo con los patrones de conexión se pueden tener diferentes tipos de propagación. La principal diferenciación se hace entre redes de avance de señal hacia delante (**feedforward**) y las redes recurrentes.

Las redes de tipo **feedforward** son aquellas cuyos datos fluyen desde la entrada hacia la salida, estrictamente hacia delante. El procesamiento puede extenderse por múltiples capas de unidades, pero no hay conexiones hacia atrás.

Las redes recurrentes, contrarias a las **feedforward**, tienen conexiones hacia atrás. En estas redes, las propiedades dinámicas de la red son importantes. En algunos casos, los valores de activación de las unidades sufren un proceso de relajación por el cual la red pasa a un estado estable, en el cual estas activaciones no cambian más.

El aprendizaje de la RNA es un proceso en el cual los parámetros libres de una red neuronal son adaptados, a través de un proceso que ajusta de acuerdo con el ambiente en el que la RNA está embebida. El tipo de aprendizaje está determinado por la forma en que toman cambio éstos parámetros⁹.

Existen varios métodos para ajustar el valor de las conexiones. Una manera consiste en efectuar el ajuste explícitamente, utilizando un conocimiento *a priori*. Otra forma consiste en “entrenar” la red neuronal artificial a partir de una enseñanza lograda según patrones y dejándola cambiar sus pesos de acuerdo con alguna regla de aprendizaje. El paradigma de aprendizaje puede ser supervisado y no supervisado.

El aprendizaje supervisado o aprendizaje asociativo, es aquel en el cual la red es entrenada de acuerdo con unos datos de entrada y unos patrones de salida de ajuste. Este mapeo entrada-salida puede lograrse por un profesor externo, o por un sistema que está contenido en la red (auto-supervisada).

El aprendizaje no supervisado o auto-organizativo es aquel que con una unidad (de salida) es entrenado para que responda a los grupos (clases) o patrones dentro del conjunto de entrada. En éste paradigma se supone que el sistema descubre de forma estadística características sobresalientes de la población de entrada. Diferente al paradigma del entrenamiento supervisado, aquí no hay un conjunto *a priori* para las categorías, en los cuales los patrones deben ser clasificados; por el contrario, el sistema debe desarrollar su propia representación del estímulo de entrada¹⁰.

Entre las diferentes aplicaciones de las redes neuronales se encuentran la clasificación de patrones, el agrupamiento por clases o categorías, la

⁹ HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999. p. 50.

¹⁰ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 18.

aproximación de funciones, las predicciones, la optimización, la memoria de contenido direccionable y el control.

La clasificación de patrones¹¹ consiste en asignar a una entrada (como un símbolo escrito a mano), un patrón representado por un vector característico de una o más clases predefinidas (ver figura 2).

Figura 2. Clasificación de patrones



Las aplicaciones más conocidas en el área de agrupamiento/categorización con RNA incluyen: reconocimiento de caracteres, reconocimiento de voz, clasificación de electrocardiogramas, clasificación de glóbulos rojos e inspección de tarjetas madre de circuitos.

Figura 3. Agrupamiento.



FUENTE: "Artificial Neural Networks: A Tutorial". Anil. K. Jain. (Michigan State University). Jianchang Mao; K. M. Mohiuddin (IBM Almaden Research Center). IEEE. Página 32.

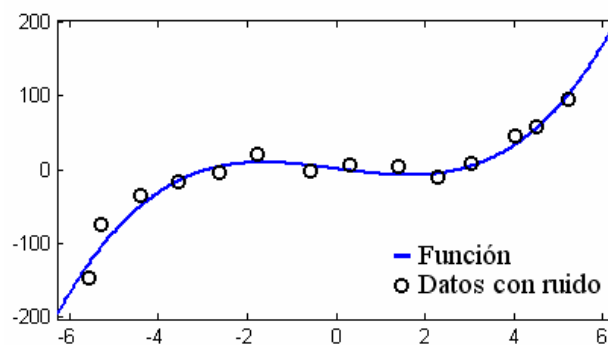
¹¹ ANIL, K. Jain; MAO, Jianchang and MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. IEEE. March, 1996. p. 32.

En el agrupamiento, también conocido como clasificación no supervisada de patrones, no hay datos de entrenamiento con etiquetas conocidas. Un algoritmo de agrupamiento explora las similitudes entre los patrones y los lugares de patrones similares en un agrupamiento (ver figura 3). Las aplicaciones más conocidas son minería de datos, compresión y análisis exploratorio de datos.

La aproximación de funciones se presenta cuando se tiene un cierto conjunto de datos con ruido y se quiere hallar una correlación (una función desconocida) entre ellos (ver figura 4).


En aquellos casos en que es extremadamente complicado despejar analíticamente la inversa de la función original, la aproximación de funciones puede utilizarse para hallar el mapeo de datos salida-entrada. Tal caso es particularmente útil cuando se desea conocer cuáles valores hay que insertar en la función original para obtener un resultado deseado.

Figura 4. Aproximación de funciones



La tarea de predicción consiste en pronosticar un valor a un tiempo futuro, dados unos datos de una secuencia de tiempo. Las aplicaciones típicas de las redes neuronales en ésta área son las predicciones en la bolsa de valores y en el estado del tiempo (ver figura 5).

Figura 5. Predicciones.



FUENTE: "Artificial Neural Networks: A Tutorial". Anil. K. Jain. (Michigan State University). Jianchang Mao; K. M. Mohiuddin (IBM Almaden Research Center). IEEE. Página 32.

Con respecto a la predicción, el ajuste de los parámetros libres de una RNA puede ser visto como una forma de construcción de modelos, en el sentido que entre más pequeño sea el error de predicción, estadísticamente hablando, mejor será el servicio que preste la red como un modelo del proceso físico subyacente, responsable de la generación de los datos. Cuando este proceso es no-lineal, el uso de la RNA se convierte en un método poderoso debido a la unidad de procesamiento no-lineal que puede ser lograda en su construcción. Una excepción al uso de la unidad de procesamiento no-lineal es aquella situación en la cual el rango dinámico de las series de tiempo es desconocida, en tales casos la escogencia de una unidad de salida lineal es la selección más razonable¹².

Una amplia variedad de problemas en matemáticas, estadística, ingeniería, ciencias, medicina y economía pueden ser planteados como problemas de optimización. El objetivo de un algoritmo de optimización es encontrar una solución satisfactoria a un conjunto de restricciones, tales como una función objetivo que debe ser maximizada o minimizada. Un clásico ejemplo de ésta situación es el del agente viajero (ver figura 6).

¹² HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999. p.73.


Figura 6. Problema del agente viajero.



FUENTE: Enciclopedia Microsoft Encarta 2004.

La memoria asociativa o memoria con contenido direccionable, como su nombre lo implica, es aquella que puede ser leída a partir de su contenido. El contenido en la memoria puede ser llamado tan solo con una parte de la entrada o con un contenido distorsionado. (Ver figura 7).

Figura 7. Memoria de contenido direccionable.




FUENTE: Microsoft Encarta 2004 y www.brainsbreaker.com.

Ésta perspectiva es más favorable en la construcción de bases de datos multimedia, porque si se opta por capturar la memoria a través de su dirección (como en el modelo computacional clásico de von Neumann), se leerá un ítem totalmente diferente si se presenta un pequeño error en el cálculo de la dirección.

En un sistema dinámico, la función del control consiste suministrar al sistema las entradas necesarias par que su salida siga una trayectoria deseada determinada por un modelo de referencia (ver figura 8).

Figura 8. Respuesta a un mecanismo de control.



1.1. REDES NEURONALES DE ALIMENTACIÓN HACIA DELANTE

Éstas redes, más conocidas como **feedforward**, son aquellas que, como su nombre lo indica, están constituidas por capas que propagan las señales estrictamente hacia adelante, sin que existan conexiones entre neuronas ni conexiones hacia atrás (ver figura 9).

Cada capa se construye como la agrupación de varias neuronas. Cada neurona recibe las señales de la capa anterior (multiplicadas por los respectivos pesos), efectúa la sumatoria y agrega el factor de desviación (ver nodo de sumatoria en la figura 10). Al resultado se le aplica la función de activación y se genera así la salida de la neurona.

Figura 9. Estructura Feedforward.

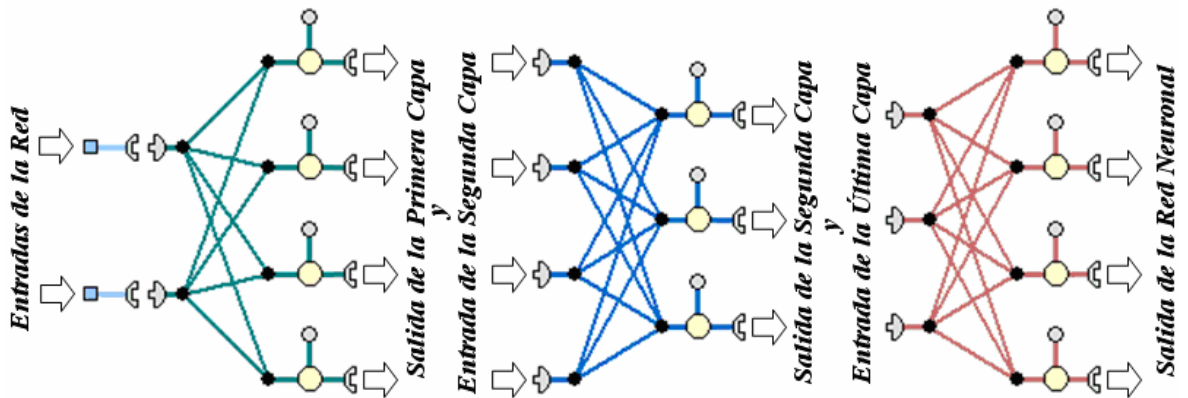
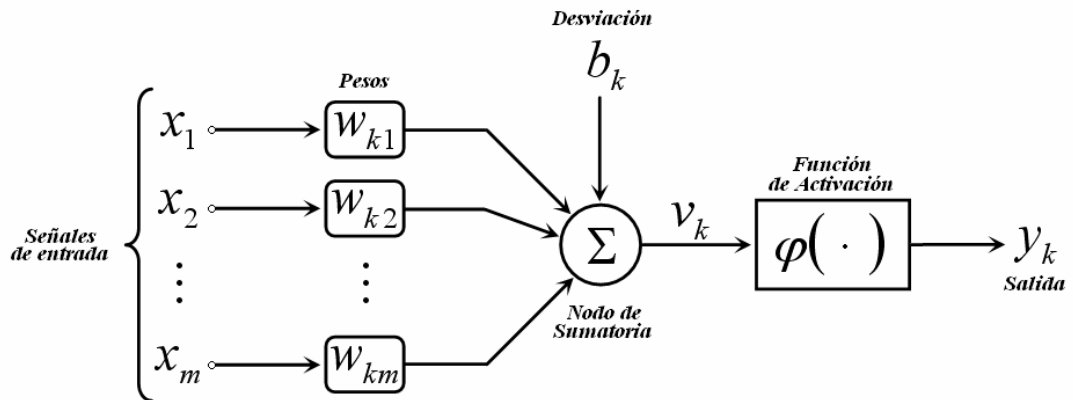


Figura 10. Estructura de una neurona.



FUENTE: "Neural Networks. A Comprehensive Foundation". HAYKIN, S. 2 ed. Prentice Hall, 1999.

En las ecuaciones 1 y 2 se presentan las expresiones que describen el funcionamiento de la neurona.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad \text{Ecuación 1.}$$

$$y_k = \varphi(u_k + b_k) \quad \text{Ecuación 2.}$$

En donde:

w_{kj} es el peso que va desde una neurona o entrada j hasta una neurona k .

m es el número de entradas a la red ó el número de salidas de una capa anterior.

x_j es el valor de una entrada de la red ó el valor de salida de una capa anterior.

b_k es el factor de desviación de una neurona.

$\varphi(\cdot)$ es la función de activación de una neurona.

y_k es una de las salidas de una capa (salida de una neurona).

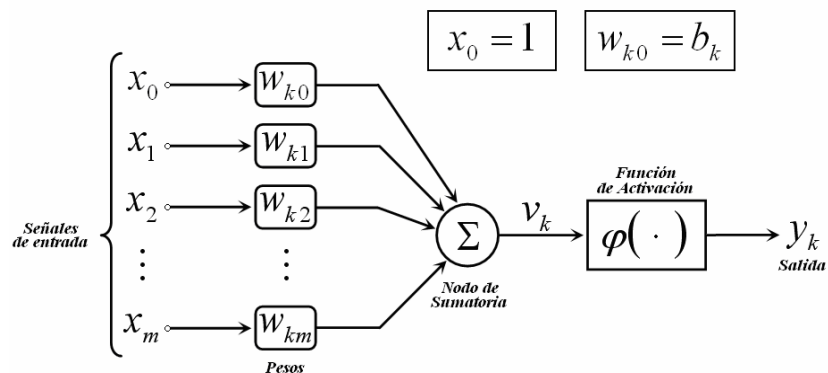
El factor de desviación puede simularse como si fuese un factor de peso b_k cuya entrada es igual a uno (ver figura 11). En tal caso las nuevas ecuaciones son:

$$v_k = u_k + b_k \text{ Ecuación 3.}$$

$$v_k = \sum_{j=0}^m w_{kj} x_j \text{ Ecuación 4.}$$

$$y_k = \varphi(v_k) \text{ Ecuación 5.}$$


Figura 11. Estructura de la neurona modificada.



FUENTE: "Neural Networks. A Comprehensive Foundation". HAYKIN, S. 2 ed. Prentice Hall, 1999.


En la figura 12 se presenta una versión simplificada de los componentes que integran una neurona.

Figura 12. Estructura simplificada de la neurona.



La figura 13 ilustra una capa construida por la adición de neuronas.

Figura 13. Estructura de una capa.



Las ecuaciones de la capa son:

$$v_j = \sum_{i=0}^m w_{ji} x_i \quad \text{Ecuación 6.}$$

$$y_j = \varphi_j(v_j), \quad j = 1, 2, \dots, q \quad \text{Ecuación 7.}$$

En la ecuación 7, q es el número de salidas de la capa. Note que en la ecuación 6 se utiliza el término x_i para denotar las entradas a la capa, estos datos pueden ser la entrada a la red o la salida de una capa anterior.

La ecuación 6 es equivalente con la expresión matricial:

$$\begin{bmatrix} v_1 \\ v_2 \\ v_3 \\ \vdots \\ v_m \end{bmatrix} = \begin{bmatrix} b_1 & w_{1,1} & w_{1,2} & \cdots & w_{1,m} \\ b_2 & w_{2,1} & w_{2,2} & \cdots & w_{2,m} \\ b_3 & w_{3,1} & w_{3,2} & \cdots & w_{3,m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ b_q & w_{q,1} & w_{q,2} & \cdots & w_{q,m} \end{bmatrix} * \begin{bmatrix} 1 \\ x_1 \\ x_2 \\ \vdots \\ x_q \end{bmatrix} \quad \text{Ecuación 8.}$$

Existen tres funciones de activación continuas y diferenciables de amplio uso en las redes **feedforward**. Estas son la función lineal (ecuación 9), la logística (ecuación 10) y la tangencial hiperbólica (ecuación 11).

$$\varphi_j(v_j) = v_j \quad \text{Ecuación 9.}$$

$$\varphi_j(v_j) = \frac{1}{1 + \exp(-a * v_j)} \quad \text{Ecuación 10.}$$


$$\varphi_j(v_j) = a * \tanh(b * v_j) \quad \text{Ecuación 11.}$$

En donde a y b son factores que definen las funciones de activación.

En la función lineal la salida es igual a la entrada v_j . Esta función es particularmente útil para ajustar datos que no han sido apropiadamente escalados,

por lo que es recomendable utilizarla en la capa de salida de la RNA. En la figura 14 se presentan tres gráficos construidos a partir de las ecuaciones 9, 10 y 11.

Figura 14. Funciones de activación derivables.



FUENTE: “Neural Networks. A Comprehensive Foundation”. HAYKIN, S. 2 ed. Prentice Hall, 1999.


La ventaja de estas ecuaciones con respecto a las de tipo escalón, está relacionada con el algoritmo de entrenamiento **backpropagation**, el cual requiere la derivación de las funciones de activación.

Para ilustrar el funcionamiento de la red **feedforward** se presenta el siguiente ejemplo. Suponga que a una red de dos capas, tal como se ilustra en la figura 15, se le insertan los datos $[x_1 = 4; x_2 = 6]$. ¿Cuál sería la respuesta de la RNA?

Las salidas de los nodos de sumatoria de la primera capa serían, según la ecuación 8:

$$\begin{bmatrix} -0.8 & 0.5 & 0.4 \\ 0.1 & 0.9 & 1 \end{bmatrix} * \begin{bmatrix} 1 \\ 4 \\ 6 \end{bmatrix} = \begin{bmatrix} 3.6 \\ 9.7 \end{bmatrix}$$

Figura 15. Ejemplo de estructura feedforward.



Si se consideran funciones logísticas para las neuronas de la primera capa, la señal que ingresa a la segunda capa sería, según la ecuación 10 y para un valor de $a = 1$:

$$\varphi\left(\begin{bmatrix} 3.6 \\ 9.7 \end{bmatrix}\right) = \begin{bmatrix} 0.9734 \\ 0.9999 \end{bmatrix}$$

La salida del nodo de sumatoria de la segunda capa es, según la ecuación 8:


$$\begin{bmatrix} -0.3 & -1.2 & 1.1 \end{bmatrix} * \begin{bmatrix} 1 \\ 0.9734 \\ 0.9999 \end{bmatrix} = \begin{bmatrix} -0.3682 \end{bmatrix}$$

Si se asume una función logística en la última capa, el resultado de la red neuronal es:

$$\varphi\left(\begin{bmatrix} -0.3682 \end{bmatrix}\right) = \begin{bmatrix} 0.4090 \end{bmatrix}$$

En la figura 16 se muestra el flujo de datos esperado en el ejemplo de la red **feedforward**.

Figura 16. Flujo de datos en la red feedforward.



1.2. ALGORITMO BACKPROPAGATION^{13,14}

Minsky y Papert¹⁵ demostraron en 1969, que una red de dos capas **feedforward** podía superar muchas restricciones no logradas por anteriores redes. Sin embargo, no dejaron la solución acerca de cómo ajustar los pesos de las unidades ocultas.

Una solución a éste problema fue presentado por Rumelhart, Hinton y Williams¹⁶ en 1986, y similares trabajos parecen haber sido publicados anteriormente por Werbos¹⁷ 1974, Parker¹⁸ 1985 y Cun¹⁹ 1985.

¹³ HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999. p. 161.

¹⁴ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 33.

¹⁵ MINSKY, M., and PAPERT, S. Perceptrons: an introduction to computational geometry. The MIT Press, 1969. Citado por: ver referencia 14.

¹⁶ RUMELHART, D. E.; HINTON, G. E. and WILLIAMS R. J. Learning representations by backpropagating errors. Nature, 323, p. 533-536. Citado por: ver referencia 14.

¹⁷ WERBOS, P. J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Unpublished doctoral dissertation, Harvard University, 1974. Citado por: ver referencia 14.

¹⁸ PARKER, D. B. Learning-Logic (Tech. Rep. Nos. TR-47). Cambridge, MA: Massachusetts Institute of Technology, Center for Computational Research in Economics and Management Science, 1985. Citado por: ver referencia 14.

¹⁹ CUN, Y. L. Une procedure d'apprentissage pour reseau a seuil assymetrique. Proceedings of Cognitiva, 85 (1985), p. 599-604. Citado por: ver referencia 14.

La idea central detrás de ésta solución, es que los errores de las unidades de las capas ocultas son determinados por una retro-propagación (**backpropagation**) de la regla de aprendizaje.

El algoritmo de **backpropagation** parte de principios básicos de optimización y es a su vez considerado como una generalización de la regla delta para funciones de activación no-lineal y redes multicapa²⁰.

En las técnicas de optimización no restringidas, la condición óptima se obtiene cuando²¹:

$$\nabla \xi(W^*) = 0 \text{ Ecuación 12.}$$

En donde:

W^* es el punto óptimo que se quiere encontrar.

$\xi(\cdot)$ es la función error a minimizar.

∇ es el operador gradiente expresado como:

$$\nabla = \left[\frac{\partial}{\partial w_1}, \frac{\partial}{\partial w_2}, \dots, \frac{\partial}{\partial w_m} \right]^T \text{ Ecuación 13.}$$

Con cada iteración se debe conseguir que:

$$\xi(W(n+1)) < \xi(W(n)) \text{ Ecuación 14.}$$

Siendo n un entero que representa las iteraciones.

²⁰ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 33.

²¹ KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996. p. 121.

El algoritmo de mayor descenso (*steepest descent*) considera que para alcanzar el punto óptimo, se debe partir de un punto inicial y avanzar en dirección contraria a la pendiente de la función error, es decir: moverse en la dirección que causaría el mayor descenso.

El tamaño del paso de avance en el algoritmo de mayor descenso está definido por un parámetro de aprendizaje η y la magnitud del gradiente (ver ecuación 15). Esta condición es desfavorable porque en las zonas de poca pendiente de la función error (zonas planas), el avance hacia el punto óptimo se hace más lento. Adicionalmente, en los casos en que la pendiente sea muy pronunciada y se haya elegido un parámetro de aprendizaje muy alto, el algoritmo puede oscilar sin convergir hacia el valor óptimo buscado.

$$W(n+1) = W(n) - \eta * g(n), \quad g = \nabla \xi(W) \quad \text{Ecuación 15.}$$

En las RNA, el objetivo del proceso de entrenamiento es ajustar los parámetros libres de la red (pesos y desviaciones) para minimizar una función de costo. Esto se puede lograr asumiendo la función error como la suma de los cuadrados de las diferencias entre los valores que se desean (valores objetivo) y los verdaderos valores obtenidos por la red.

La función a minimizar en el algoritmo más sencillo de **backpropagation** es:

$$\xi(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad \text{Ecuación 16.}$$

En donde:

$$e_k(n) = d_k(n) - y_k(n) \quad \text{Ecuación 17.}$$

En la ecuación 17, el término $d_k(n)$ corresponde al valor que se espera obtener al simular la red y el término $y_k(n)$ es el resultado realmente obtenido por la RNA.

En la ecuación 16, el número dos que actúa como exponente garantiza que el error siempre será positivo. Por otra parte, el número dos que se encuentra en el denominador fue colocado por conveniencia debido a que al derivar la función error, éste dato se cancela durante la operación.

Por aplicación de la regla de la cadena se tiene que:

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = \frac{\partial \xi(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial w_{kj}(n)} \quad \text{Ecuación 18.}$$

La forma en que se propaga hacia atrás del error cometido por la RNA es la piedra angular que define al algoritmo de **backpropagation**. El cambio en los pesos en la última capa es diferente al que se efectúa en el resto de las capas. Por lo tanto, primero se definirá la pendiente del error con respecto a los pesos en la última capa. Para ello se define un subíndice k que representa una neurona ubicada en la capa de salida de la RNA y el subíndice j indica las neuronas de la capa oculta anterior a la última capa.

Partiendo del error en una sola neurona de la capa de salida de la RNA y según la ecuación 16 (note que el número dos del denominador desaparece con la derivación) se tiene que:

$$\frac{\partial \xi(n)}{\partial e_k(n)} = e_k(n) \quad \text{Ecuación 19.}$$

De la ecuación 17:

$$\frac{\partial e_k(n)}{\partial y_k(n)} = -1 \quad \text{Ecuación 20.}$$

De la definición de la función de activación:

$$\frac{\partial y_k(n)}{\partial v_k(n)} = \varphi'_k(v_k(n)) \text{ Ecuación 21.}$$

De la ecuación 6:

$$\frac{\partial v_k(n)}{\partial w_{kj}(n)} = y_j(n) \text{ Ecuación 22.}$$

Juntando todos los términos de la regla de la cadena, se tiene que para la última capa de la RNA:

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = -e_k(n) \varphi'_k(v_k(n)) y_j(n) \text{ Ecuación 23.}$$

Se define el gradiente local como:

$$\delta_k(n) = -\frac{\partial \xi(n)}{\partial v_k(n)} \text{ Ecuación 24.}$$

Y por regla de la cadena:

$$\delta_k(n) = -\frac{\partial \xi(n)}{\partial w_{kj}(n)} \frac{\partial w_{kj}(n)}{\partial v_k(n)} \text{ Ecuación 25.}$$

Si se reemplazan las ecuaciones 23 y 22 en la ecuación 25 se tiene que:

$$\delta_k(n) = e_k(n) \varphi'_k(v_k(n)) \text{ Ecuación 26.}$$

Por lo tanto, el delta que se debe efectuar sobre los pesos de la última capa es:

$$\Delta w_{kj}(n) = \eta \delta_k(n) y_j(n) \text{ Ecuación 27a.}$$

Ésta ecuación puede ser modificada de manera que el cambio actual tenga en cuenta una parte del cambio que se obtuvo en la iteración pasada. De allí surge la ecuación delta generalizada (ver ecuación 27b).

$$\Delta w_{kj}(n) = \eta \delta_k(n) y_j(n) + \alpha \Delta w_{kj}(n-1) \text{ Ecuación 27b.}$$

En donde el factor α se conoce como constante de momentum.

Extendiendo el concepto de gradiente local a las neuronas ubicadas en las capas ocultas se tiene que:

$$\delta_j(n) = -\frac{\partial \xi(n)}{\partial v_j(n)} = -\frac{\partial \xi(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial \xi(n)}{\partial y_j(n)} \phi'_j(v_j(n)) \text{ Ecuación 28.}$$

En este punto es en donde se encuentran las ecuaciones que definen la forma en que se propaga hacia atrás el error. Retomando la ecuación 16 se obtiene:

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \text{ Ecuación 29.}$$

De acuerdo con la ecuación 17:

$$e_k(n) = d_k(n) - \phi_k(v_k(n)) \text{ Ecuación 30.}$$

Por lo tanto:

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\phi'_k(v_k(n)) \text{ Ecuación 31.}$$

Y según la ecuación 6:

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \text{ Ecuación 32.}$$

Reemplazando las ecuaciones 31 y 32 en la ecuación 29 se tiene que:

$$\frac{\partial \xi(n)}{\partial y_j(n)} = -\sum_k e_k(n) \varphi'_k(v(n)) w_{kj}(n) = -\sum_k \delta_k(n) w_{kj}(n) \text{ Ecuación 33.}$$

Sustituyendo la ecuación 33 en la ecuación 28 se obtiene:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \text{ Ecuación 34.}$$

Note que el error que se le asigna a las neuronas “ocultas”, depende de los gradientes locales de las neuronas que se encuentran en la capa inmediatamente después (delante) de la capa que se está modificando en sus pesos (mecanismo de propagación hacia atrás del error).

El cambio en los pesos en las neuronas ocultas está dado por la ecuación:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \text{ Ecuación 35a.}$$

En consecuencia, para las neuronas “ocultas”, la ecuación delta generalizada es:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) + \alpha \Delta w_{ji}(n-1) \text{ Ecuación 35b.}$$

Por definición, la modificación en los pesos viene dada por la ecuación:

$$W(n+1) = W(n) + \Delta W(n) \text{ Ecuación 36.}$$

En las ecuaciones 37a, 37b y 37c, se presentan las soluciones de los gradientes locales para la última capa de la RNA según las funciones lineal, logística y tangencial hiperbólica, respectivamente.

$$\delta_k(n) = [O_k(n)][d_k(n) - O_k(n)] \quad \text{Ecuación 37a.}$$

$$\delta_k(n) = [a O_k(n)(1 - O_k(n))][d_k(n) - O_k(n)] \quad \text{Ecuación 37b.}$$

$$\delta_k(n) = \left[\frac{b}{a} (a - O_k(n))(a + O_k(n)) \right] [d_k(n) - O_k(n)] \quad \text{Ecuación 37c.}$$

Para hacer claridad sobre la diferencia entre la salida total de la red y la salida de una neurona de una capa oculta, se definió $O_k(n)$ como el valor obtenido al evaluar la RNA.

En las ecuaciones 38a, 38b y 38c, se presentan las soluciones de los gradientes locales para las capas ocultas de la RNA según las funciones lineal, logística y tangencial hiperbólica, respectivamente.

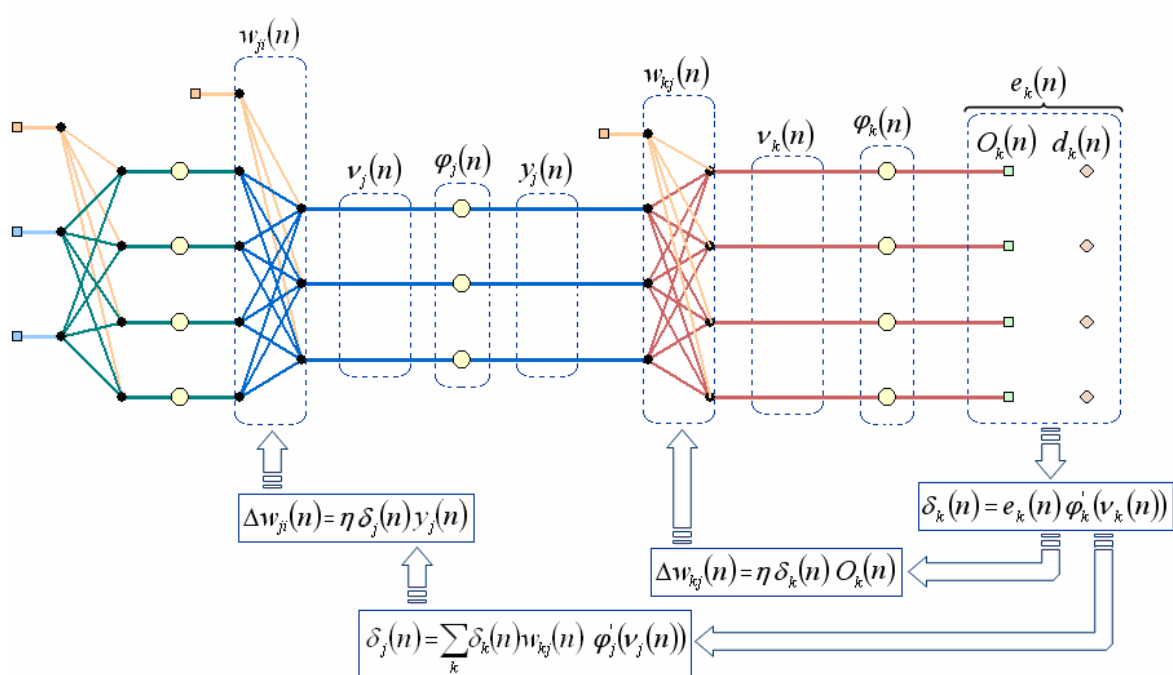
$$\delta_j(n) = [y_j(n)] \left[\sum_k \delta_k(n) w_{kj}(n) \right] \quad \text{Ecuación 38a.}$$

$$\delta_j(n) = [a y_j(n)(1 - y_j(n))] \left[\sum_k \delta_k(n) w_{kj}(n) \right] \quad \text{Ecuación 38b.}$$

$$\delta_j(n) = \left[\frac{b}{a} (a - y_j(n))(a + y_j(n)) \right] \left[\sum_k \delta_k(n) w_{kj}(n) \right] \quad \text{Ecuación 38c.}$$

En la figura 17 se muestra un esquema de la propagación hacia atrás de los errores y las correcciones respectivas en los pesos y las desviaciones de las capas de la RNA.

Figura 17. Esquema del algoritmo backpropagation.



Para ilustrar el uso del algoritmo de **backpropagation** se vuelve al ejemplo de la RNA en estructura **feedforward**, pero ésta vez se asume que para los valores de entrada $[x_1 = 4; x_2 = 6]$ el resultado de la RNA debe ser $d_1 = 9$. Por lo tanto, el gradiente local de la neurona ubicada en la última capa es, de acuerdo con la ecuación 37b:

$$\delta_k(1) = [1 * 0.4090 * (1 - 0.4090)][9 - 0.4090] = 2.0766$$

Siendo $\eta = 0.1$, el delta de pesos y desviaciones de la última capa es:

$$\Delta w_{1,1}(1) = [0.1 * 2.0766 * 1] = 0.20766 \quad (\text{ver ecuación 27a})$$

$$\Delta w_{1,2}(1) = [0.1 * 2.0766 * 0.9734] = 0.20214 ; \quad \Delta w_{1,3}(1) = [0.1 * 2.0766 * 0.9999] = 0.20765$$

$$\Delta W_{\text{últ. capa}}(1) = [0.20766 \quad 0.20214 \quad 0.20765]$$

La nueva matriz de pesos y desviaciones de la última capa es (ver ecuación 36):

$$W_{\text{últ. capa}}(2) = [-0.3 \quad -1.2 \quad 1.1] + [0.20766 \quad 0.20214 \quad 0.20765]$$

$$W_{\text{últ. capa}}(2) = [-0.09234 \quad -0.99786 \quad 1.30765]$$

Los gradientes locales de las neuronas de la primera capa son (ver ecuación 38b):

$$\delta_1(1) = [1 * 0.9734 * (1 - 0.9734)][2.0766 * (-1.2)] = -0.0645$$

$$\delta_2(1) = [1 * 0.9999 * (1 - 0.9999)][2.0766 * 1.1] = 0.0001$$

El delta de pesos y desviaciones de la primera capa es (ver ecuación 35a):

$$\Delta w_{1,1}(1) = 0.1 * (-0.0645) * 1 = -0.00645 ; \quad \Delta w_{1,2}(1) = 0.1 * (-0.0645) * 4 = -0.02581$$

$$\Delta w_{1,3}(1) = 0.1 * (-0.0645) * 6 = -0.03871 ; \quad \Delta w_{2,1}(1) = 0.1 * (0.0001) * 1 = 0.00001$$

$$\Delta w_{2,2}(1) = 0.1 * (-0.0001) * 4 = 0.00006 ; \quad \Delta w_{2,3}(1) = 0.1 * (-0.0001) * 6 = 0.00008$$

$$\Delta W_{\text{pri. capa}}(1) = \begin{bmatrix} -0.00645 & -0.02581 & -0.03871 \\ 0.00001 & 0.00006 & 0.00008 \end{bmatrix}$$

Por lo tanto, la nueva matriz de pesos y desviaciones de la primera capa es (ver ecuación 36):


$$W_{pri. capa}(2) = \begin{bmatrix} -0.8 & 0.5 & 0.4 \\ 0.1 & 0.9 & 1.0 \end{bmatrix} + \begin{bmatrix} -0.00645 & -0.02581 & -0.03871 \\ 0.00001 & 0.00006 & 0.00008 \end{bmatrix}$$

$$W_{pri. capa}(2) = \begin{bmatrix} -0.80645 & 0.47419 & 0.36129 \\ 0.10001 & 0.90006 & 1.00008 \end{bmatrix}$$

En la figura 18 se muestra el nuevo resultado que se obtiene al actualizar los pesos y las desviaciones de la RNA.

Note que el nuevo resultado está más cercano al valor deseado $d_1 = 9$, porque se pasó de un valor de $O_1(1) = 0.4090$ a un valor de $O_1(2) = 0.5632$. Se esperaría que al aplicar sucesivamente el algoritmo de **backpropagation**, el resultado tienda al valor deseado $d_1 = 9$; sin embargo, la limitación de la función de activación escogida (logística) para la última capa, no permitirá un resultado mayor que uno (ver figura 14). Por eso se sugiere que la última capa tenga funciones de activación de tipo lineal.

Figura 18. Nuevo resultado después de hacer una iteración backpropagation.



El ejemplo presentado sólo evalúa una pareja de datos entrada-salida, pero en realidad lo que usualmente se tiene es un conjunto de parejas de datos que representan las entradas y los valores objetivo. En tal caso se recomienda que los datos se presenten de forma aleatoria y se actualicen de forma secuencial y no por batches. Esto es, que se cambien los pesos con cada iteración, pero que la secuencia de presentación de las parejas se haga de forma aleatoria para garantizar el correcto aprendizaje de la RNA (ver siguiente ejemplo para mayor claridad).

Para ilustrar el entrenamiento de varios datos se analiza el problema del XOR (operador \vee exclusivo).

Tabla 1. Tabla de verdad del XOR.

Índice	P	Q	XOR(P,Q)
I	1	1	0
II	1	0	1
III	0	1	1
IV	0	0	0


En éste problema se define un número máximo de épocas de entrenamiento. Cada época es una presentación de todos los ejemplos que se necesita que sean aprendidos por la RNA.

Por ejemplo, en la primera época se puede entrenar la red con los datos presentados en el orden II, IV, I, III según el índice; esto es: $x_1 = (1,0), d_1 = (1)$; $x_2 = (0,0), d_2 = (0)$; $x_3 = (1,1), d_3 = (0)$; $x_4 = (0,1), d_4 = (1)$. Luego, en la siguiente época, se vuelve a cambiar el orden de presentación según el índice por ejemplo I, IV, III, II; lo que supone una presentación de parejas de la forma $x_1 = (1,1), d_1 = (0)$; $x_2 = (0,0), d_2 = (0)$; $x_3 = (0,1), d_3 = (1)$; $x_4 = (1,0), d_4 = (1)$.

Sin importar el orden de presentación de los datos, se recomienda hacer la actualización de los pesos y desviaciones de forma secuencial. Es decir, que no se espera a terminar la época, sino que con cada pareja de datos se actualizan los pesos y desviaciones de la RNA.


Si se parte de una red como la que se muestra en la figura 19 y se efectúa el entrenamiento **backpropagation**, el problema del XOR quedaría resuelto tal como se muestra en la figura 20.

Figura 19. Punto de partida para la solución del XOR con una RNA.



La red fue entrenada 4000 épocas, con un parámetro $\eta = 0.1$ y un factor $\alpha = 0.5$. Se tienen funciones logísticas en todas las capas.

Figura 20. Solución encontrada con una RNA para el problema del XOR.



Los pesos y desviaciones que se muestran en la figura 20 no son los únicos parámetros de red válidos para resolver el problema del XOR. Por ejemplo, otra combinación de pesos y desviaciones que también sirve es:

$$W_{pri.capa} = \begin{bmatrix} 1.9593 & 5.9999 & -4.5236 \\ 0.4045 & 3.0538 & 3.0212 \\ 1.8819 & -4.4299 & 5.9727 \end{bmatrix}$$

$$W_{ult.capa} = [4.7125 \quad -6.6727 \quad 5.5069 \quad -6.6720]$$

Esta multiplicidad de respuestas válidas, se debe a que en la búsqueda del menor valor para la función de error, se puede llegar a diferentes mínimos locales que satisfacen las condiciones de detención del entrenamiento. Tales mínimos locales aumentan en la medida en que aumenta el número de neuronas y el número de capas, porque entre más parámetros libres se tengan, mayores serán las combinaciones que satisfagan una misma condición.

Si se quiere calcular un error promedio en cada iteración **backpropagation**, se puede utilizar la siguiente ecuación:

$$\xi_{av} = \frac{1}{2R} \sum_{n=1}^R \xi(r) = \frac{1}{2R} \sum_{r=1}^R \sum_{m=1}^M (d_m(r) - y_m(r)) \text{ Ecuación 39.}$$

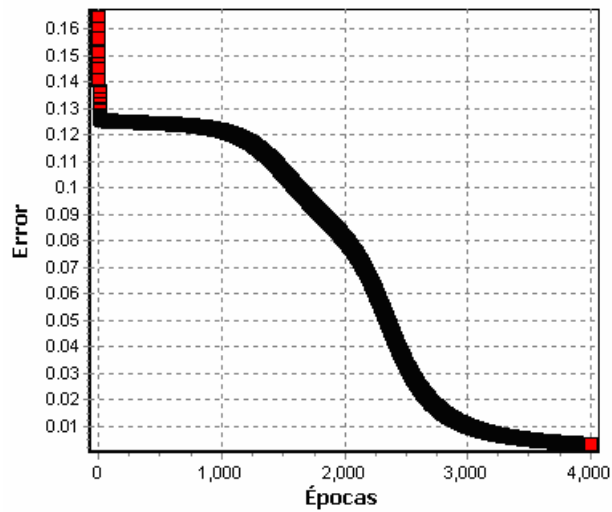
En donde:

R es el número de muestras.

M es el número de salidas de la RNA.

En la figura 21 se muestra la variación del error a medida que avanza el entrenamiento.

Figura 21. Avance del error con respecto a las épocas.



Para que el entrenamiento **backpropagation** funcione mejor, se puede²² seguir la siguiente heurística:

1. Actualizar los pesos y desviaciones secuencialmente y no por batches.
2. Maximizar el contenido de la información.
 - Utilizar ejemplos que resulten en el mayor error de entrenamiento y que sean radicalmente diferentes a los anteriores.
 - Hacer aleatorio el orden en el cual se presentan los ejemplos de una época a otra.
3. El aprendizaje es de mayor velocidad cuando la función de activación es antisimétrica que cuando no es simétrica. Para la función tangencial hiperbólica se recomienda $a = 1.7159$ y $b = 2/3$.
4. Los valores objetivo deben ser escogidos dentro del rango de la función de activación.
5. Se deben normalizar las entradas.
6. Es favorable utilizar, para el aprendizaje, la información que se tiene de la función en estudio, procurando acelerar la búsqueda y mejorar la estimación.

²² HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999. p. 174

Adicionalmente, se puede modificar el algoritmo de entrenamiento. Por un lado se puede dejar de lado la versión simple del steepest descent para explorar otras alternativas ofrecidas por las técnicas de optimización. Por otra parte, se puede incorporar la teoría de Tikhonov quien propuso un método llamado regularización para resolver problemas mal-puestos (*ill-posed problems*).

En el contexto de la reconstrucción de una hipersuperficie²³, la idea básica de la regularización es estabilizar la solución por algunas funcionales auxiliares no-negativas que incorporan información conocida acerca de la solución. La forma más común de información previa incluye la suposición de que la función de mapeo entrada-salida (solución al problema de reconstrucción) es suave, en el sentido que entradas similares corresponden a entradas similares. Tal incorporación de la teoría de la regularización se obtiene incluyendo en la función de error a minimizar, un término de regularización.

Otra alternativa es el uso de razonamientos tales como el criterio de selección de Occam (Occam's razor), que plantea que de diferentes modelos disponibles, el modelo a seleccionar debe ser el menos complejo. En redes neuronales, este criterio puede ser incorporado a través de la teoría de probabilidad de Bayes²⁴.

²³ HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999. p. 267.

²⁴ MACKAY, David. Bayesian Methods for Adaptive Models. PhD. Thesis. California Institute of Technology, 1992. p. 7.

2. ELEMENTOS BÁSICOS DEL FLUJO EN POZOS PETROLÍFEROS

Antes de definir los modelos de redes neuronales artificiales, es necesario hacer claridad acerca de los fundamentos teóricos que determinan el comportamiento de producción en un campo petrolífero; para poder definir con bases teóricas sólidas, las variables, las modificaciones que se harán en los datos de entrenamiento y en el mecanismo de validación de los resultados.

En éste capítulo se resumen algunos elementos de la ingeniería de petróleos, necesarios para la comprensión de los modelos de simulación en redes neuronales que se propondrán en capítulos posteriores.

2.1. DECLINACIÓN DE PRODUCCIÓN EN POZOS PETROLÍFEROS

En su artículo de 1956, Arps plantea su ecuación base para la declinación de producción. Su expresión matemática parte de la premisa de que si un pozo no ha sido sometido a ningún cambio significativo en sus condiciones mecánicas (sin cambios en el sistema de levantamiento artificial, sin estimulaciones, sin recañoneos) y que si las condiciones de producción del yacimiento no han cambiado (sin implementar nuevos mecanismos de recobro mejorado, sin perforar nuevos pozos que intervengan la producción del pozo en estudio), entonces el comportamiento de declinación del pozo a futuro será similar al comportamiento observado en el pasado²⁵.

²⁵ ARPS, J. J. Estimation of primary oil reserves. Trans. AIME, 207, 1956. p. 187-188.

La expresión básica propuesta por Arps (ecuación 40) define la variación de la producción con respecto al tiempo, como una función del caudal instantáneo, de un coeficiente k y un exponente de declinación n .

$$D = kq^n = \frac{-dq/dt}{q} \quad \text{Ecuación 40.}$$

En donde t es el tiempo y D es la declinación como una fracción del caudal.

La fortaleza del modelo de Arps no se encuentra solamente en la efectividad con que pronostica los caudales, sino también en su sencillez, ya que permite expresar la declinación de un pozo conociendo únicamente sus datos de caudal versus tiempo (información recolectada periódicamente en todos los campos petrolíferos).

De la integración de la ecuación básica se derivan los tres comportamientos característicos de la declinación: exponencial, hiperbólico y armónico. A continuación se presentan las derivaciones de éstos modelos de declinación.

Primero se despeja la ecuación 40 de la siguiente manera:

$$kq^{n+1} = -\frac{dq}{dt} \quad \text{Ecuación 40a.}$$

Integrando entre t_o y t y entre q_i y q_t se tiene que: $\int_{t_o}^t k dt = \int_{q_i}^{q_t} -\frac{dq}{q^{n+1}}$

El comportamiento exponencial es el que se tiene cuando $n = 0$ y $t_o = 0$. Entonces:

$$kt = \int_{q_i}^{q_t} -\frac{dq}{q} = -\ln q \Big|_{q_i}^{q_t} = -\ln q_t - (-\ln q_i) = \ln q_i - \ln q_t = \ln \frac{q_i}{q_t} \Rightarrow e^{kt} = \frac{q_i}{q_t}$$

Teniendo en cuenta que $D_i = kq_i^n \Rightarrow D_i = k$, el comportamiento exponencial está regido por la expresión:

$$q_t = \frac{q_i}{e^{D_i t}} \quad \text{Ecuación 41.}$$

Los parámetros que arrojan un comportamiento hiperbólico son $n \neq 0$ y $t_o = 0$.

Entonces:

$$\int_{t_o}^t k dt = \int_{q_i}^{q_t} -\frac{dq}{q^{n+1}} = kt = \int_{q_i}^{q_t} -q^{-(n+1)} dq = \frac{-q^{-(n+1)+1}}{-(n+1)+1} \Big|_{q_i}^{q_t} = \frac{-q^{-n}}{-n} \Big|_{q_i}^{q_t} = \frac{1}{nq^n} \Big|_{q_i}^{q_t}$$

$$\Rightarrow kt = \frac{1}{n} \left[\frac{1}{q_t^n} - \frac{1}{q_i^n} \right] \Rightarrow nkt = \frac{1}{q_t^n} - \frac{1}{q_i^n} \Rightarrow nkt + \frac{1}{q_i^n} = \frac{1}{q_t^n} = \frac{kq_i^n nt + 1}{q_i^n}$$

Teniendo en cuenta que $D_i = kq_i^n$, se obtiene:

$$\frac{1}{q_t^n} = \frac{D_i nt + 1}{q_i^n} \Rightarrow q_t^n = \frac{q_i^n}{D_i nt + 1}$$

Entonces el comportamiento hiperbólico está regido por la expresión:

$$q_t = \frac{q_i}{(D_i nt + 1)^{\frac{1}{n}}} \quad \text{Ecuación 42.}$$

Si $n = 1$, se dice que el comportamiento es armónico según:

$$q_t = \frac{q_i}{D_i t + 1} \quad \text{Ecuación 43.}$$

En realidad, se tienen sólo dos tipos de declinación: la exponencial y la hiperbólica, siendo la armónica un caso particular de la hiperbólica. Para resolver la ecuación exponencial (ecuación 41), basta con conocer dos parejas (t, q_t) .

$$D_i = \frac{\ln q_1 - \ln q_2}{t_2 - t_1} \text{ Ecuación 44a.}$$

$$q_i = q_1 * \exp(D_i * t_1) \text{ Ecuación 44b.}$$

Si se tienen más de dos parejas de datos (t, q_t) , el problema se encuentra sobredeterminado. Para encontrar los parámetros, se puede utilizar un despeje de tipo matricial²⁶.

Despejando ecuación 41 y efectuando el logaritmo natural en ambos lados se tiene:

$$\ln(q_i) = \ln(q_t) + \ln(e^{D_i t}) = \ln(q_t) + D_i t \text{ Ecuación 45a.}$$

Asumiendo que $A = \ln(q_i)$ y $B = \ln(q_t)$ se tiene:

$$A - D_i t = B \text{ Ecuación 45b.}$$

Cuando se tienen $n > 2$ parejas (t, q_t) se presenta un conjunto del tipo:

$$\begin{array}{rclcl} A & - & D_i t_1 & = & B_1 \\ A & - & D_i t_2 & = & B_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ A & - & D_i t_n & = & B_n \end{array}$$

²⁶ NAKAMURA, Shoichiro. Análisis numérico y visualización gráfica con Matlab. Prentice Hall, 1997. p. 295.

Éste conjunto expresado de forma matricial tendría la forma:

$$\begin{bmatrix} 1 & -t_1 \\ 1 & -t_2 \\ \vdots & \vdots \\ 1 & -t_n \end{bmatrix} * \begin{bmatrix} A \\ D_i \end{bmatrix} = \begin{bmatrix} B_1 \\ B_2 \\ \vdots \\ B_n \end{bmatrix}$$

Asumiendo que:

$$C = \begin{bmatrix} 1 & -t_1 \\ 1 & -t_2 \\ \vdots & \vdots \\ 1 & -t_n \end{bmatrix}, X = \begin{bmatrix} A \\ D_i \end{bmatrix}, R = \begin{bmatrix} B_1 \\ B_2 \\ \vdots \\ B_n \end{bmatrix}$$

Se tiene la expresión:

$$CX = R \text{ Ecuación 46.}$$

Si C es una matriz cuadrada invertible (problema determinado bien puesto), la solución a las incógnitas es un problema simple de despeje de álgebra de matrices:

$$C^{-1} * C * X = C^{-1} * R = I * X$$

$$\Rightarrow X = C^{-1} * R \text{ Ecuación 47.}$$

Pero, en los casos sobredeterminados C no es una matriz cuadrada, por lo que es necesario ajustarla primero con la matriz transpuesta, entonces:

$$(C^T * C) * X = C^T * R$$

Suponiendo que $M = (C^T * C)$ es invertible, se tiene:

$$M * X = C^T * R$$

$$\Rightarrow X = M^{-1} * C^T * R$$

$$\Rightarrow X = (C^T * C)^{-1} * C^T * R \text{ Ecuación 48.}$$

De acuerdo con lo anterior se sabe que $q_i = \exp(X_{1,i})$ y que $D_i = X_{2,i}$. En la tabla 2 se presenta un conjunto de datos de producción que se quiere declinar desde la perspectiva exponencial.

Tabla 2. Datos de producción para el ejemplo exponencial*.

Tiempo (días)	Fecha	Caudal (Bls/día)	Ln(Caudal)
0	11-Feb-92	226.7	5.42
88	9-May-92	260.4	5.56
229	27-Sep-92	223.6	5.41
376	21-Feb-93	213.0	5.36
482	7-Jun-93	210.0	5.35
607	10-Oct-93	170.0	5.14
748	28-Feb-94	197.3	5.28
839	30-May-94	158.1	5.06
1001	8-Nov-94	160.3	5.08
1182	8-May-95	116.5	4.76
1335	8-Oct-95	115.0	4.74
1480	1-Mar-96	84.0	4.43
1702	9-Oct-96	77.9	4.36

* Datos reales tomados de un pozo de un campo colombiano. Se omite el nombre por acuerdo de confidencialidad.

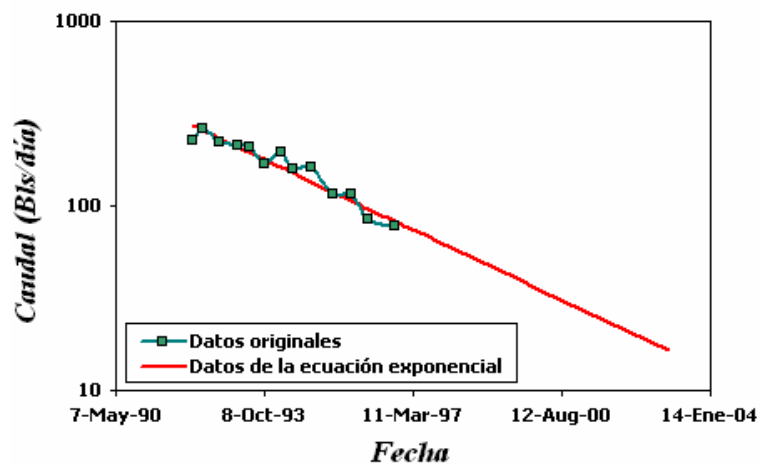
Las matrices quedarían de la siguiente manera:

$$C = \begin{bmatrix} 1 & 0 \\ 1 & -88 \\ 1 & -229 \\ 1 & -376 \\ 1 & -482 \\ 1 & -607 \\ 1 & -748 \\ 1 & -839 \\ 1 & -1001 \\ 1 & -1182 \\ 1 & -1335 \\ 1 & -1480 \\ 1 & -1702 \end{bmatrix}, R = \begin{bmatrix} 5.42 \\ 5.56 \\ 5.41 \\ 5.36 \\ 5.35 \\ 5.14 \\ 5.28 \\ 5.06 \\ 5.08 \\ 4.76 \\ 4.74 \\ 4.43 \\ 4.60 \end{bmatrix}$$

De acuerdo con la ecuación 48 se obtiene: $X = (C^T * C)^{-1} * C^T * R = \begin{bmatrix} 5.6064 \\ 0.0007 \end{bmatrix}$

Por lo tanto $q_i = 272.16$ y $D_i = 0.0007$. (Ver resultados en la figura 22).

Figura 22. Ejemplo de declinación exponencial.



Con respecto al cálculo de los parámetros de declinación hiperbólica, la ecuación 42 no puede resolverse directamente porque los datos de interés no pueden ser despejados analíticamente. Por lo tanto, es necesario apoyarse en técnicas computacionales para hallar los valores de q_i , D_i y n .

Inicialmente, la solución hiperbólica se planteó a través de gráficos^{27,28} debido a la poca disposición de computadores personales de la época. Pero con el tiempo, el cálculo de los parámetros de declinación hiperbólica se automatizó con la ayuda de las técnicas de optimización, algoritmos genéticos²⁹, entre otros³⁰.

Para ilustrar un ejemplo de declinación hiperbólica se presenta la siguiente tabla de datos de producción.

Tabla 3. Datos de producción para el ejemplo hiperbólico*.

Tiempo (días)	Fecha	Caudal (Bls/día)
0	11-Feb-92	389.9
229	27-Sep-92	256.4
482	7-Jun-93	216.8
748	15-Feb-94	155.2
1001	8-Nov-94	131.2
1182	8-May-95	110.9
1335	8-Oct-95	113.5
1480	1-Mar-96	84.0
1702	9-Oct-96	88.1

* Datos reales tomados de un pozo de un campo colombiano. Se omite el nombre por acuerdo de confidencialidad.

²⁷ GENTRY, R. W. Decline Curve Analysis. En: Journal of Petroleum Technology (Enero, 1972). SPE 3356.

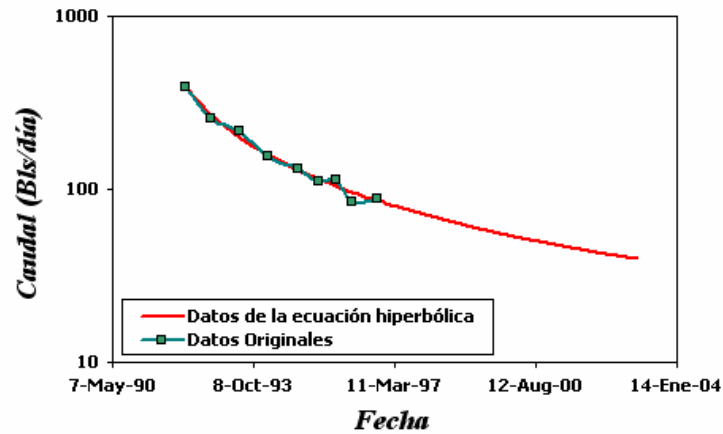
²⁸ LIN, Ch and ROWLAND D. A. Determining the constants of hyperbolic production decline by a linear graphic method. En: Society of Petroleum Engineers (1982). SPE 11329.

²⁹ JIKICH, S. A. and POPA, A. S. Hyperbolic Decline Parameter Identification Using Optimization Procedures. En: Society of Petroleum Engineers (2000). SPE 65634.

³⁰ RUZ, S. y CALDERÓN, Z. Estimación de reservas y cálculo de los parámetros de declinación hiperbólica. Una comparación entre redes neuronales y métodos numéricos. En: Congreso Colombiano del Petróleo (11º : 2005: Bogotá).

Estos datos fueron cargados en la herramienta de ajuste de curvas³¹ de Matlab (marca registrada de The MathWorks Inc.). Los resultados encontrados para los parámetros fueron $q_i = 387.1$, $D_i = 0.001855$ y $n = 0.8919$. (Ver figura 23).

Figura 23. Ejemplo de declinación hiperbólica.



Las expresiones para el cálculo del caudal acumulado, pueden obtenerse a partir de la integración con respecto al tiempo de las ecuaciones de caudal versus tiempo. (N_p es el acumulado de producción).

$$N_p = \int_{t_1}^{t_2} q_t dt \quad \text{Ecuación 49.}$$

Para el comportamiento exponencial:

$$\Rightarrow N_p = \int_{t_1}^{t_2} q_i e^{-D_i t} dt = \frac{q_i}{D_i} \left(-e^{-D_i t_2} + e^{-D_i t_1} \right)$$

Siendo: $q_1 = q_i e^{-D_i t_1}$ y $q_2 = q_i e^{-D_i t_2}$, entonces:

$$N_p = \frac{q_1 - q_2}{D_i} \quad \text{Ecuación 50.}$$

³¹ The Mathworks Inc. Curve Fitting Toolbox. User's Guide. Version 1. 2001-2002.

Para el comportamiento hiperbólico:

$$N_p = \int_{t_1}^{t_2} q_i (1 + nD_i t)^{-\frac{1}{n}} dt \quad \text{Ecuación 51.}$$

$$\Rightarrow N_p = \frac{-q_i \left(-(1 + nD_i t_1)^{\frac{1}{n}} - nD_i t_2 (1 + nD_i t_1)^{\frac{1}{n}} + (1 + nD_i t_2)^{\frac{1}{n}} + nD_i t_1 (1 + nD_i t_2)^{\frac{1}{n}} \right)}{D_i (-1 + n) (1 + nD_i t_1)^{\frac{1}{n}} (1 + nD_i t_2)^{\frac{1}{n}}}$$

$$\Rightarrow N_p = \frac{q_i}{D_i (1 - n)} \left(\frac{(1 + nD_i t_2)^{\frac{1}{n}} (1 + nD_i t_1) - (1 + nD_i t_1)^{\frac{1}{n}} (1 + nD_i t_2)}{(1 + nD_i t_1)^{\frac{1}{n}} (1 + nD_i t_2)^{\frac{1}{n}}} \right)$$

$$\Rightarrow N_p = \frac{q_i}{D_i (1 - n)} \left(\frac{(1 + nD_i t_1)}{(1 + nD_i t_1)^{\frac{1}{n}}} - \frac{(1 + nD_i t_2)}{(1 + nD_i t_2)^{\frac{1}{n}}} \right)$$

Siendo $q_1 = q_i (1 + nD_i t_1)^{-\frac{1}{n}}$ y $q_2 = q_i (1 + nD_i t_2)^{-\frac{1}{n}}$, entonces:

$$N_p = \frac{1}{D_i (1 - n)} (q_1 (1 + nD_i t_1) - q_2 (1 + nD_i t_2))$$

Partiendo de:

$$q = q_i (1 + nD_i t)^{-\frac{1}{n}} = \frac{q_i}{(1 + nD_i t)^{\frac{1}{n}}} \Rightarrow \left((1 + nD_i t)^{\frac{1}{n}} \right)^n = \left(\frac{q_i}{q} \right)^n = (1 + nD_i t) = \frac{q_i^n}{q^n}$$

$$\Rightarrow N_p = \frac{1}{D_i (1 - n)} \left(\frac{q_1 q_i^n}{q_1^n} - \frac{q_2 q_i^n}{q_2^n} \right) = \frac{q_i^n}{D_i (1 - n)} (q_1^{(1-n)} - q_2^{(1-n)})$$

Por consiguiente:

$$N_p = \frac{q_i^n}{D_i} \left(\frac{q_1^{(1-n)} - q_2^{(1-n)}}{1-n} \right) \text{ Ecuación 52.}$$

2.2. ECUACIÓN DE FLUJO A ESTADO SEUDO-ESTABLE


La declinación propuesta por Arps, a pesar de su utilidad, se encuentra limitada a un cierto tipo de problemas de la ingeniería de petróleos. Esto se debe a que adolece de las variables y las relaciones necesarias para comprender mejor el flujo que ocurre en un pozo petrolífero.

La ecuación de flujo a estado pseudo-estable permite caracterizar la producción de un pozo a partir de variables tales como la presión del yacimiento, el radio de drenaje, la presión de fondo fluyente, entre otras. Aunque se considera al pozo como un elemento aislado, ésta ecuación es suficiente para inferir qué tipo de cambios se presentarán en el caudal al modificar las condiciones de producción.

La derivación de la ecuación de flujo estado pseudo-estable comienza desde una relación encontrada alrededor de 1856 por Darcy. A partir de un modelo macroscópico, Darcy estableció que el caudal de flujo a través de un medio poroso es directamente proporcional al área transversal de flujo, a una constante c y a la diferencia de cabeza hidráulica; e inversamente proporcional a la longitud que deba recorrer el fluido³².

³² GOLAN, M. and WHITSON, C. H. Well Performance. 2 ed. Prentice Hall, Englewoods Cliffs, NJ, 1991. p. 110.

Figura 24. Ilustración del método utilizado por Darcy para desarrollar su ecuación de flujo.



FUENTE: "Golan, M. and Whitson, C. H.: "Well Performance", Prentice Hall, Englewoods Cliffs, NJ, Second Edition (1991). Página 110.

La expresión matemática para el caudal es:

$$q = cA(h_1 - h_2)/L = cA[(p_1 - p_2)/\delta g + L \sin \alpha]/L \quad \text{Ecuación 53.}$$

En donde:

- q es el caudal de líquido que atraviesa el lecho poroso.
- c es un factor que caracteriza al sistema.
- A es el área transversal de flujo.
- h_i es la columna hidrostática de un punto i .
- z_i es la altura de un punto i .
- p_i es una presión en un punto i .
- δ densidad del fluido que atraviesa el lecho poroso.
- g constante gravitacional.
- α inclinación del lecho poroso.
- L longitud entre dos puntos del lecho poroso.

Si se tiene flujo horizontal, la ecuación 53 se convierte en:

$$q = cA\Delta p/L \quad \text{Ecuación 54.}$$

Sólo hasta 1934, Wycoff, Botset y Meres³³ separaron la constante c en dos factores independientes llamados viscosidad y permeabilidad, convirtiendo la ecuación en:

$$v = \left(\frac{k}{\mu}\right) \frac{(p_2 - p_1)}{L} \quad \text{Ecuación 55.}$$

En donde:

k es la permeabilidad del lecho poroso.

μ es la viscosidad del fluido que atraviesa el lecho poroso.

Debido a que en el yacimiento se tiene un flujo radial desde la formación hacia el pozo (ver figura 25) la ecuación de Darcy debe resolverse de acuerdo con:

$$v = \frac{qB}{2\pi rh} = \left(\frac{k}{\mu}\right) \frac{dp}{dr} \quad \text{Ecuación 56.}$$


En donde B es el factor volumétrico de formación y r es el radio (ver figura 26 para mayor claridad). Integrando la ecuación 56, se tiene:

$$\frac{2\pi kh}{q\mu B} \int_{p_{wf}}^p dp = \int_{r_w}^r \frac{dr}{r}$$

³³ WYCOFF, R. D.; BOTSET, H. G.; MUSKAT, M. and MERES, M. W. Flow of gas-liquid mixtures through sand. Transactions of AIME, 1937. Vol. 123. p. 69-96. Citado en: GOLAN, M. and WHITSON, C. H. Well Performance. 2 ed. Prentice Hall, Englewoods Cliffs, NJ, 1991. p. 111.

$$\Rightarrow p(r) = p_{wf} + \frac{q\mu B}{2\pi kh} \ln\left(\frac{r}{r_w}\right) \text{ Ecuación 57a.}$$

Figura 25. Esquema de flujo yacimiento-pozo.



En unidades de campo y asumiendo flujo monofásico de crudo, la ecuación 57a se convierte en:

$$p(r) = p_{wf} + \frac{141.2 q_o \mu_o B_o}{kh} \ln\left(\frac{r}{r_w}\right) \text{ Ecuación 57b.}$$

En donde:

- q_o es el caudal de aceite, STB/D.
- μ_o es la viscosidad del aceite, cp.
- B_o es el factor volumétrico de formación, bbl/STB.
- k es la permeabilidad al aceite, mD.
- h es el espesor de la formación, pies.
- r es el radio evaluado, pies.
- $p(r)$ es la presión en un punto a una distancia r , psia.

p_{wf} es la presión de fondo fluyente, psia.

r_w es el radio del pozo.

La ecuación 57 supone que:

- El yacimiento tiene un espesor constante.
- El pozo penetra todo el espesor del yacimiento.
- El flujo es puramente radial.
- La permeabilidad es homogénea e isotrópica en toda la región de drenaje.
- El pozo está limpio y sin revestimiento.
- La ley de Darcy es aplicable a toda el área de drenaje.

Para pasar de la ecuación 57 a la ecuación de flujo en estado pseudo-estable, se evalúa desde el radio del pozo hasta el radio de drenaje y se incorpora la presión promedia del yacimiento, la cual según Craft y Hawkins³⁴ es equivalente a la presión que se encuentra a casi la mitad de la distancia del radio externo, esto es:

$$p_R = p(r = 0.472r_e) \text{ Ecuación 58.}$$

Bajo estas condiciones se infiere la caída ideal de presión para el estado pseudo-estable:


$$p_R - p_{wf} = \frac{141.2q_o\mu_oB_o}{kh} \left[\ln\left(\frac{r_e}{r_w}\right) - 0.75 \right] \text{ Ecuación 59.}$$

La figura 26 resume el esquema de flujo radial anteriormente expuesto.

³⁴ CRAFT B. C. and HAWKINS M. F. Applied Petroleum Reservoir Engineering. 1991. Prentice Hall. p. 243.

La diferencia entre la presión de fondo fluente ideal p_{wf}^* y la presión de fondo fluente real p_{wf} se debe a un factor conocido como skin (s). Este factor representa el efecto de daño o estimulación ocurrido en los alrededores del pozo.

Figura 26. Esquema de flujo radial.



FUENTE: H. Dale Beggs. "Production Optimization Using NODAL analysis". OGCI 1999. Pág. 11.

Un pozo se "daña" cuando se presentan obstrucciones al flujo que pueden ser causadas, entre otras razones, por migración de partículas finas, precipitación de orgánicos o inorgánicos, taponamiento bacteriano, invasión del lodo de perforación y emulsiones. Entre los trabajos con los que se puede remediar un pozo dañado se tienen los fracturamientos hidráulicos, estimulación ácida y la estimulación orgánica. El factor skin adimensional se define según:

$$s = \frac{kh}{141.2q_o\mu_o B_o} \Delta p_s \quad \text{Ecuación 60.}$$

Luego, la ecuación 60 se convierte en:

$$q_o = \frac{kh(p_R - p_{wf})}{141.2\mu_o B_o \left[\ln\left(\frac{r_e}{r_w}\right) - 0.75 + s \right]} \quad \text{Ecuación 61a.}$$

Si se tiene flujo multifásico, el término de permeabilidad (k) debe ser modificado por k_o , el cual representa la permeabilidad efectiva al aceite en presencia de otros fluidos.

$$q_o = \frac{k_o h (p_R - p_{wf})}{141.2 \mu_o B_o \left[\ln\left(\frac{r_e}{r_w}\right) - 0.75 + s \right]} \quad \text{Ecuación 61b.}$$

La permeabilidad efectiva k_o está definida como el producto de la permeabilidad absoluta k por la permeabilidad relativa al aceite (k_{ro}). Este último dato puede obtenerse a partir de pruebas de laboratorio hechas sobre muestras de roca.

$$k_o = k * k_{ro} \quad \text{Ecuación 62.}$$

Algunas veces es mejor expresar el efecto del daño o de la estimulación en términos de la eficiencia de flujo, definida como:

$$E_F = \frac{q_{actual}}{q_{ideal}} \quad \text{Ecuación 62a.}$$

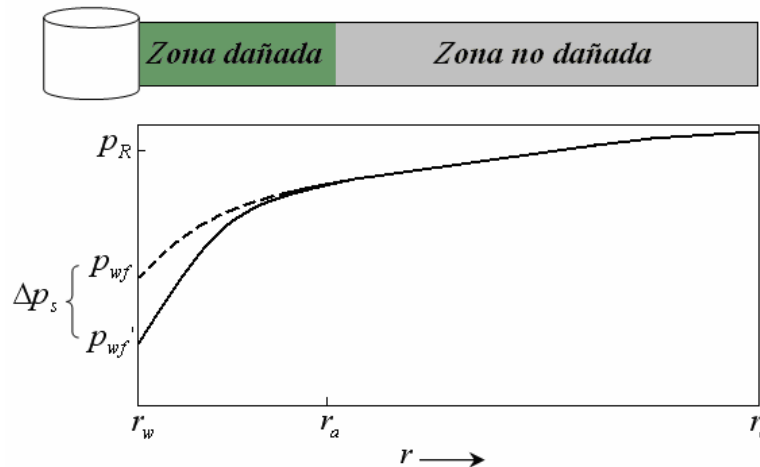
$$\Rightarrow E_F = \frac{\ln\left(\frac{r_e}{r_w}\right) - 0.75}{\ln\left(\frac{r_e}{r_w}\right) - 0.75 + s}$$

Como en la mayoría de los pozos el término $\ln\left(\frac{r_e}{r_w}\right)$ se encuentra en un rango de 6.5 a 8.5, la ecuación de eficiencia se puede aproximar a:

$$E_F = \frac{7}{7 + s} \quad \text{Ecuación 62b.}$$

La figura 27 ilustra los perfiles de presión causados en una formación con factor de daño. En ésta figura se incluye el término Δp_s que es la caída de presión adicional debida al factor de daño.

Figura 27. Caída de presión por factor de daño.



FUENTE: Golan, M. and Whitson, C. H.: "Well Performance", Prentice Hall, Englewoods Cliffs, NJ, Second Edition (1991). Página 127.

2.3. CURVA IPR

La relación existente entre la presión de fondo fluyente y el caudal del pozo (reportado en superficie y a un tiempo fijo), se conoce como relación de desempeño del flujo de entrada (IPR por su definición en inglés: *inflow performance relation*).

Para hacer una proyección del caudal de aceite por un cambio inmediato en la presión de fondo fluyente (v.gr.: diseño del sistema de levantamiento artificial), el IPR es mucho más fuerte que cualquier otra ecuación, incluso más que la ecuación de flujo a estado pseudo-estable. Esto se debe a que el IPR enlaza, de

manera sencilla, factores que de otra manera requerirían demasiada (y muy precisa) información, seguido de diversas ecuaciones y correlaciones. Por ejemplo, si se quisiera calcular el cambio en el caudal utilizando la ecuación de flujo a estado pseudo-estable se debería conocer al menos:

- Una prueba PVT, para saber las viscosidades y factores volumétricos a diferentes presiones de fondo.
- El espesor neto de la formación (proveniente de una interpretación de registros eléctricos de pozo).
- Las permeabilidades relativas en función de las saturaciones (para calcular las permeabilidades efectivas).
- El radio de drenaje y el factor de daño.
- El factor de daño aparente debido a la obstrucción causada por el gas liberado durante la reducción de la presión de fondo fluyente.

La ecuación IPR más utilizada es la propuesta por Vogel:

$$\frac{q_L}{q_{L(\max)}} = 1 - 0.2 \left(\frac{p_{wf}}{p_R} \right) - 0.8 \left(\frac{p_{wf}}{p_R} \right)^2 \quad \text{Ecuación 63.}$$

En donde q_L es el caudal de líquido reportado en superficie y $q_{L(\max)}$ es el caudal de líquido máximo que se puede lograr por reducción de la presión de fondo fluyente.

Si se conoce la presión promedio p_R la ecuación 63 puede ser resuelta con un solo dato de (q_L, p_{wf}) . No es recomendable que se utilicen dos datos de (q_L, p_{wf}) para hallar $q_{L(\max)}$ y p_R al mismo tiempo, porque generalmente se obtienen resultados desviados de la realidad.


Para ilustrar el cálculo de la curva IPR se resuelve un ejemplo de un pozo en flujo monofásico de crudo. Suponiendo que se tiene una presión promedio de 2500 psi y una pareja de producción $(q_o, p_{wf}) = (473.6, 1500)$, se tiene que:

$$q_{o(\max)} = \frac{q_o}{1 - 0.2 \left(\frac{p_{wf}}{p_R} \right) - 0.8 \left(\frac{p_{wf}}{p_R} \right)^2} = \frac{473.6}{1 - 0.2 * \left(\frac{1500}{2500} \right) - 0.8 * \left(\frac{1500}{2500} \right)^2} = 800$$

Por lo tanto el IPR (ver figura 28) se calcula con la expresión:

$$q_o = 800 * \left(1 - 0.2 \left(\frac{p_{wf}}{2500} \right) - 0.8 \left(\frac{p_{wf}}{2500} \right)^2 \right)$$

Figura 28. Ejemplo de IPR.



2.4. INFLUENCIAS ENTRE POZOS

Una manera simplificada de ver el efecto de un pozo sobre otro, consiste en construir curvas de distribuciones de presión. Tales curvas sirven para establecer las áreas de drenaje y las influencias entre pozos.

De acuerdo con la ecuación de flujo a estado pseudo-estable (ecuación 61a), la presión en un punto cualquiera, separado a una distancia r y en flujo monofásico de aceite, está dada por la ecuación 64.

$$p(r) = \frac{141.2 q_o \mu_o B_o \left[\ln\left(\frac{r}{r_w}\right) - 0.75 + s \right]}{kh} + p_{wf} \quad \text{Ecuación 64.}$$

Para un pozo con los datos $B_o = 1.05$ bbl/STB; $p_{wf} = 603.6$ psi; $s = 2.54$; $q_o = 256.7$ STB/D; $k = 203$ mD; $h = 119$ pies; $\mu_o = 31.69$ cp ; $r_w = 0.354$ pies; el perfil de presión en la formación (ecuación 64), está dado por:

$$p(r) = \frac{141.2 * 256.7 * 31.69 * 1.05 * [\ln(r) - \ln(0.354) - 0.75 + 2.54]}{203 * 119} + 603.6$$

$$\Rightarrow p(r) = 49.926 * \ln(r) + 744.814$$

El resultado en cartesiano se muestra en la figura 29 y el mismo resultado, pero en escala de colores se presenta en la figura 30.

Figura 29. Perfil de presión en cartesiano.

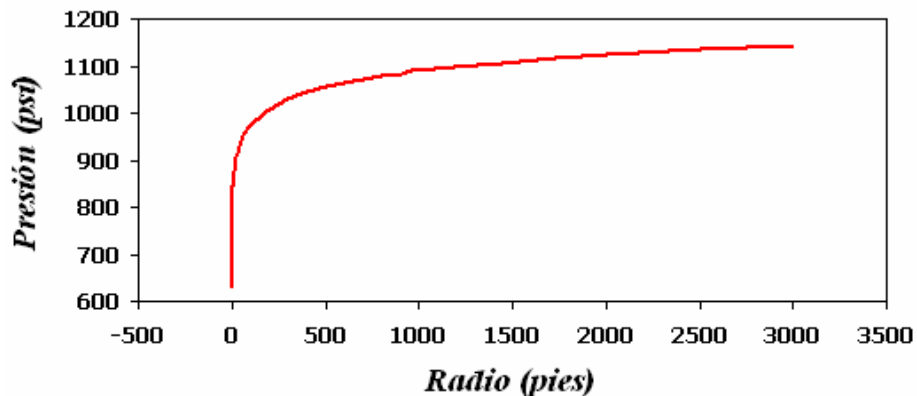




Figura 30. Perfil de presión en matices de colores.



Visto como una superficie, el perfil de presión parece un cono tal como se muestra en la figura 31.

Figura 31. Perfil de presión en forma de superficie.



Cuando varios pozos actúan al mismo tiempo, se puede presentar un fenómeno de interferencia en los perfiles de presión. Ésta superposición de perfiles (ver figura 32) hace que las áreas de drenaje de los pozos se afecten mutuamente y, eventualmente, las producciones también podrían verse afectadas.

Figura 32. Superposición de perfiles de presión en modo superficie.





Figura 33. Delimitación de áreas de drenaje.



En la figura 33 se señalan en rojo los límites de drenaje, de acuerdo con los perfiles de presión calculados con la ecuación de flujo a estado pseudo-estable. Note que el área de drenaje dejó de ser circular y también es diferente para cada uno de los tres pozos.

Si se modifica alguna de las variables de la ecuación de flujo a estado pseudo-estable, se tendrá un cambio inmediato en el área de drenaje y por lo tanto una modificación de las condiciones de producción de todos los pozos.

3. MODELO SUSTITUTO INTELIGENTE EN REDES NEURONALES PARA LA SIMULACIÓN DE YACIMIENTOS

La simulación numérica se ha convertido en la herramienta estándar de la industria del petróleo para la administración de yacimientos. Esto se debe a que sus modelos, son una excelente integración de todas las medidas de datos dinámicos y estáticos, convirtiéndose en una importante fuente de información y predicción, para la toma de decisiones.

Estos modelos numéricos se actualizan constantemente y, en situaciones normales, la nueva versión siempre es mejor que la anterior, porque contiene la última información (geología, geofísica, petrofísica, interpretaciones de registros, datos sísmicos, datos de producción-inyección, etc.) incorporada, además de las correcciones que usualmente son el resultado de un ajuste histórico de la producción de los pozos.

Actualmente, no existe una alternativa seria para reemplazar a los simuladores. La simulación de yacimientos es una disciplina ampliamente estudiada y usualmente se trabaja de la mano de modeladores altamente experimentados.

Los modelos de simulación dividen el yacimiento en bloques. Según el número de pozos, los espesores de formación y la precisión que se requiera en los resultados, se puede llegar a simular millones de celdas.

A medida que el modelo del yacimiento crece, el tiempo de simulación hace lo mismo. Aunque algunos esquemas de enmallado y procesamiento en paralelo han sido implementados para mejorar el tiempo de corrida, aún existe una gran diferencia entre las simulaciones y el procesamiento de datos en tiempo real.

Por otra parte, la nueva tecnología de pozos inteligentes, hace cada vez más necesario un sistema de procesamiento de datos en tiempo real. Los modelos sustitutos de yacimientos (SRM por su sigla en inglés: *Surrogate Reservoir Models*) son una solución clara para éste tipo de problemas, procurando simulaciones que están en un rango de segundos o minutos, en vez de horas o días, tal como sucede con la simulación convencional³⁵.

Los SRM podrían, eventualmente, emular el comportamiento del yacimiento con una alta precisión y, adicionalmente, estarían en condiciones de estar conectados en tiempo real a los generadores de datos del campo, por lo que serían muy útiles en la toma temprana de decisiones.

Las redes neuronales artificiales (RNA) tienen las características necesarias para la construcción de un SRM. Un modelo de éste tipo (SIRMANN por la sigla en inglés de Modelo Inteligente y Sustituto de Yacimiento hecho con Redes Neuronales Artificiales: *Surrogate Intelligent Reservoir Model built with Artificial Neural Networks*), podría aprovechar las ventajas de las redes neuronales artificiales para copiar, en tiempo real, la respuesta del yacimiento bajo diferentes escenarios (diferentes valores para los parámetros que determinan el comportamiento del yacimiento).

La efectividad de un SIRMANN depende de la selección apropiada de la RNA y los parámetros dinámicos que afectan la producción del yacimiento.

Cuando se habla de datos dinámicos, se está haciendo referencia a aquellos que varían con cada iteración de entrenamiento de la RNA. Es importante tener claro éste concepto, porque no se puede esperar que la RNA aprenda de un dato que se mantiene totalmente constante.

³⁵ SHAHAB M. Surrogate Intelligent Models (SIMs).
Disponible en internet en: <<http://shahab.pe.wvu.edu/research/SIM/SRM.html>>

Por ejemplo, si lo que se quiere simular es el comportamiento de producción de los pozos, el sistema es cambiante con respecto al tiempo, por lo que se pueden utilizar variables tales como la presión de fondo fluyente, los caudales de producción, la presión del yacimiento, etc. Por otra parte, si lo que se pretende es mirar cómo varía una propiedad con respecto al espacio, se puede entrenar la RNA con datos tales como la porosidad y el porcentaje de arcillas, que se suponen constantes en el tiempo, pero que son variantes con respecto a la posición.

Un modelo sustituto de yacimiento construido con redes neuronales (SIRMANN), puede ser abordado desde dos perspectivas. La primera analizando el pozo como un elemento aislado y la segunda como un conjunto de pozos que actúan y se interfieren simultáneamente.

En éste capítulo se presenta una revisión exhaustiva de múltiples modelos, que son una articulación entre los principios de las redes neuronales artificiales, explicados en el primer capítulo, y los fundamentos del flujo de fluidos expuestos en el capítulo segundo; con el objetivo de mostrar el mayor número de combinaciones posibles y explicar los principios lógicos que llevan a la propuesta de cada modelo. Todo esto, partiendo desde la forma más sencilla hasta la más elaborada.

3.1. ANÁLISIS INDIVIDUAL DE POZOS CON RNA

Viendo al pozo como un elemento aislado, es posible predecir el comportamiento de producción de la forma que lo hace el principio de declinación de Arps o de la manera que se plantea según la ecuación de flujo a estado pseudo-estable. La diferencia entre ambos métodos, está determinada por el número de variables que se quieran incorporar. Obviamente, entre más variables significativas sean incluidas, el modelo puede llegar a ser más sólido y confiable.

Adicionalmente, sería más fácil de utilizar porque parte de datos reportados normalmente por el personal de campo (ver figura 36). Note que la configuración de salida de la red de la figura 35, también puede incluir los volúmenes y/o caudales de las otras fases (agua y gas).

Figura 35. Declinación con RNA tipo II.






Figura 36. Declinación con RNA tipo III.



En la figura 36 se puede cambiar el término de presión de fondo fluyente p_{wf} por el valor del nivel de fluido, dado que, según el principio físico intrínseco, el efecto en la RNA debe ser el mismo.

En caso de que se quiera evaluar el efecto de una fase sobre otra, se puede pasar alguna, o algunas, de las variables de salida de volúmenes a la zona de variables de entrada (ver figura 37).

Figura 37. Declinación con RNA tipo IV.



De la ecuación de flujo a estado pseudo-estable (ecuación 61b), es posible identificar la información disponible que aún no ha sido incorporada al modelo.

Según su característica dinámica y la facilidad con que puede obtenerse (pruebas de presión estáticas o pruebas de presión ascendente), la presión promedio del yacimiento (p_R) sería el siguiente dato entrada para la RNA, completando las variables principales y dejándole a la RNA, el trabajo de inferir en su entrenamiento, la relación:

$$\frac{k_o h}{141.2 \mu_o B_o \left[\ln \left(\frac{r_e}{r_w} \right) - 0.75 + s \right]}$$

De éste reducto de ecuación se tiene que:


- Los valores para B_o y μ_o pueden correlacionarse a partir de los datos de presión y temperatura.
- El factor de daño s se calcula de las pruebas de presión y/o utilizando software especializado de análisis de declinaciones; este dato de factor de daño también puede extenderse en el tiempo con base en correlaciones

derivadas de la ecuación de flujo a estado pseudo-estable y de la ecuación de eficiencia de flujo³⁶.

- La permeabilidad efectiva se obtiene, multiplicando la permeabilidad absoluta por el valor leído de las curvas de permeabilidad relativa versus saturaciones.
- El radio de drenaje r_e se deduce a partir del área de drenaje.
- Los valores de k , r_w y h asumen constantes (la red no aprende de los datos constantes).

En la figura 38 se presenta el esquema general para el análisis individual de pozos productores. Cada uno de los datos, tanto de entrada como de salida, debe estar reportado a un valor de tiempo. Por otra parte, la selección de variables depende del análisis que se quiera hacer y de la disponibilidad de información que se tenga.

Figura 38. Esquema general de RNA para un solo pozo en análisis.



El esquema RNA para un pozo productor puede ser extrapolado para pozos inyectores de agua. En tal caso, la variable de entrada de mayor interés es la presión de inyección y la de salida el caudal de agua inyectado.

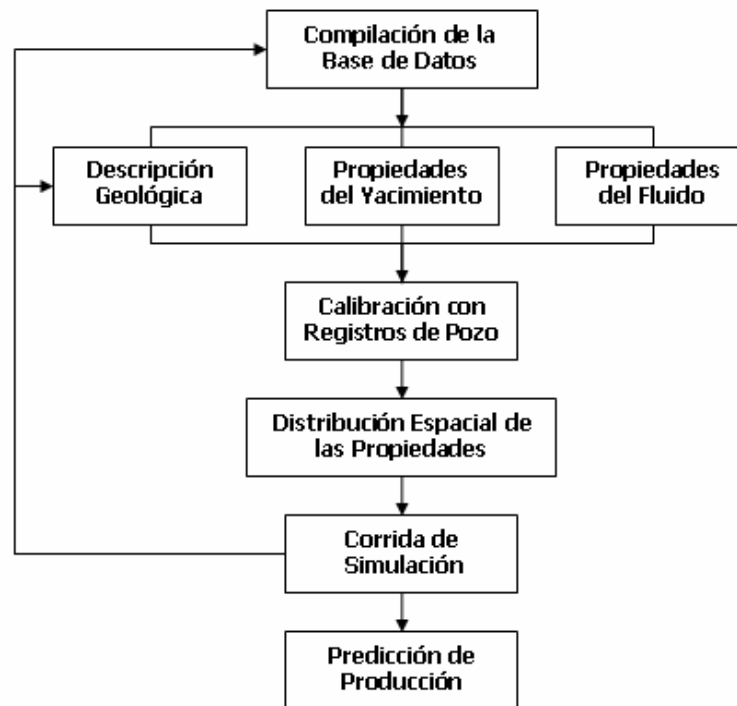
³⁶ RUZ, S. and MENDOZA, A. Stimulation Jobs Evaluation Based on Decline Curve Analysis. En: Revista CT&F – Ciencia, Tecnología y Futuro, 2006. Vol. 3. Num. 2. p. 104.

3.2. ANÁLISIS DE MÚLTIPLES POZOS CON RNA

En la simulación clásica (la que no utiliza técnicas de inteligencia artificial), se empieza por construir un modelo estático a partir de tres tipos principales de datos:

- Descripción geológica (datos de sísmica, surveys de pozos, etc.)
- Propiedades del yacimiento (permeabilidades, porosidad, calidades de roca, saturaciones, etc.)
- Propiedades del fluido (viscosidades, factores volumétricos, etc.)

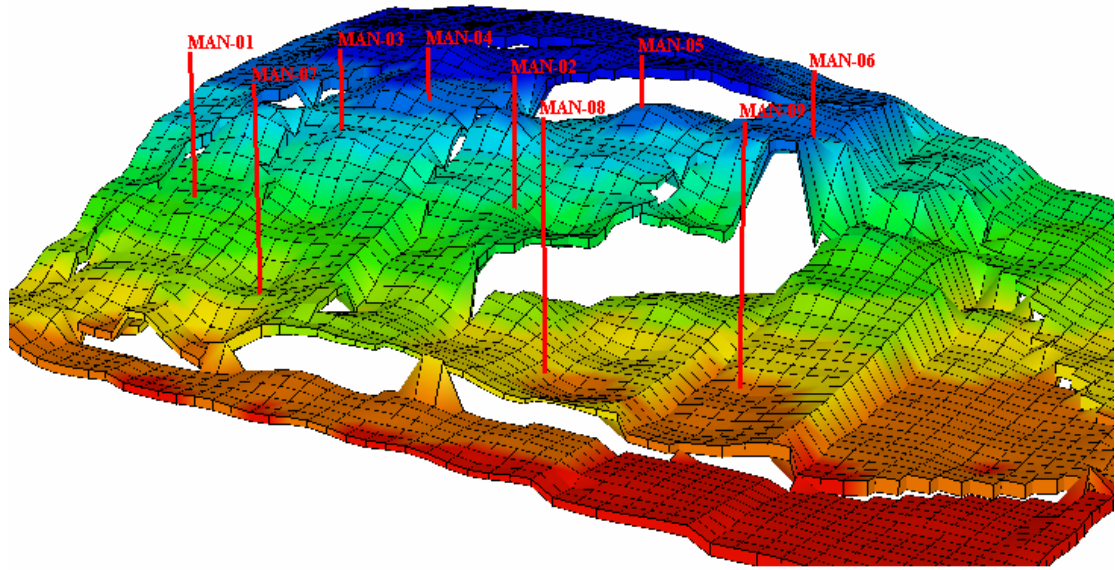
Figura 39. Etapas de la descripción del yacimiento.



FUENTE: M. L. Wiggins, R. A. Startzman.: "An Approach to Reservoir Management". SPE 20747. Página 333.

El modelo inicial es dividido en pequeños bloques (ver figura 40) para poder aplicar las ecuaciones diferenciales (difusividad, transferencia de calor, etc.) resueltas en diferencias finitas.

Figura 40. Yacimiento dividido en bloques para simulación numérica.

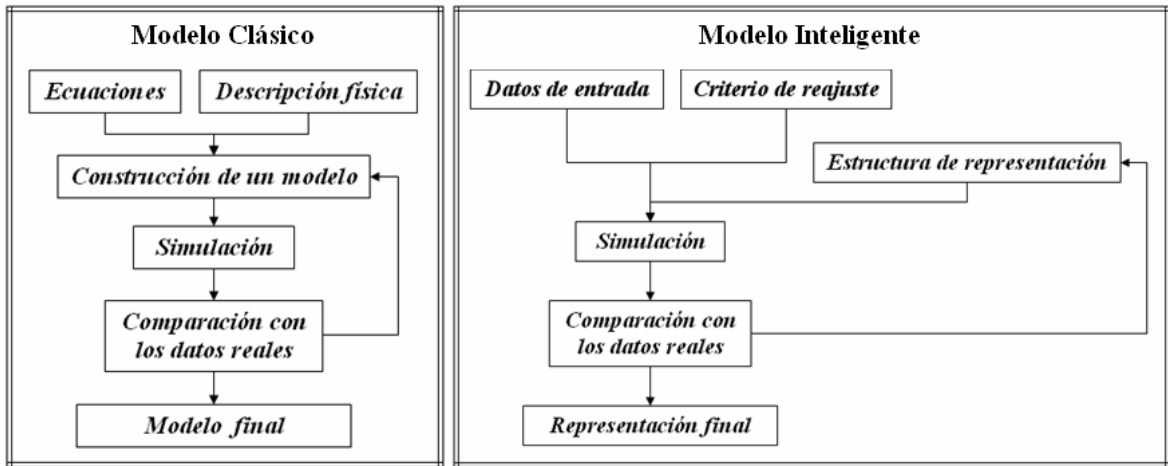


Los valores de los parámetros de cada bloque son recalculados en cada iteración del tiempo de simulación. Los resultados dependen principalmente de las condiciones (presiones de fondo, volúmenes de inyección, cantidad de calor introducida en el yacimiento, etc.) en las que se coloca a producir el yacimiento.

Si la respuesta del modelo simulado no concuerda con la realidad (datos de producción reales), el modelo estático se reajusta (figura 39).

En la visión clásica de simulación, el modelo que se ajusta es el estático, procurando que la respuesta de la corrida de simulación coincida con los datos reales de producción. Por el contrario, en el SIRMANN son los datos dinámicos los responsables de la construcción misma del modelo, por lo que no se limitan a la labor de verificación (ver figura 41).

Figura 41. Comparación de modelos de descripción del yacimiento.



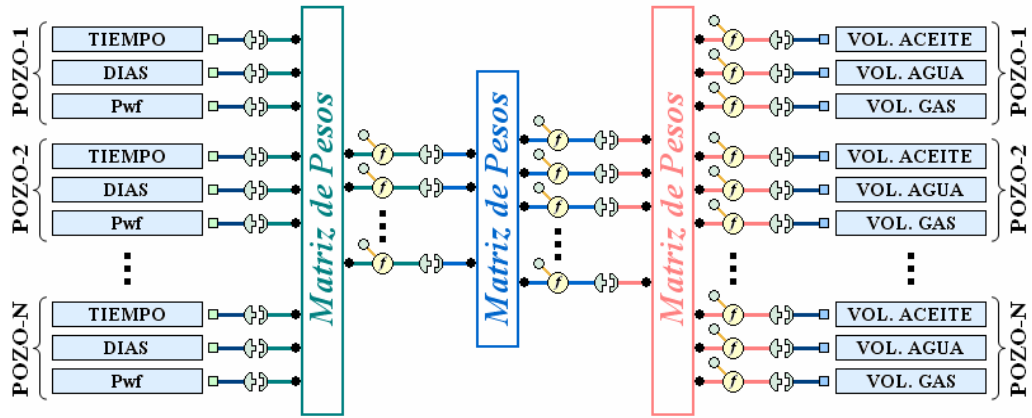
Esta flexibilidad del modelo SIRMANN hace que su ajuste sea automático y muy sencillo. Sin embargo, es posible que las respuestas del modelo inteligente se salgan de la realidad física del problema en estudio.

Siguiendo la estrategia utilizada para predecir la producción de un solo pozo petrolífero, se puede analizar el yacimiento como la suma de componentes individuales (en este caso pozos).

La aproximación inicial consiste en colocar, al igual que en un simulador numérico, los valores de presiones de fondo, para que la RNA aprenda el resto de relaciones durante el entrenamiento (ver figura 42).

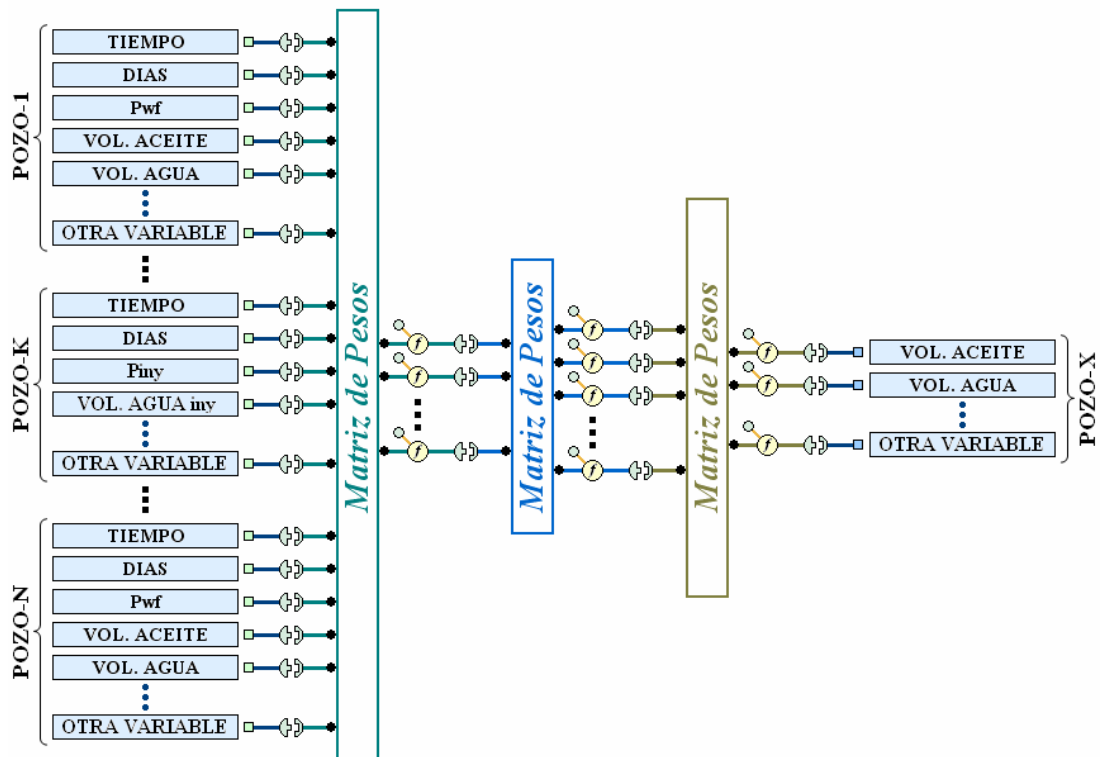
Para analizar un pozo equis en el esquema SIRMANN, se pueden pasar los valores de producción de los pozos no analizados, al sector de entradas de la RNA. De este modo se debe obtener un análisis individual de pozo más sólido, porque se le incorpora mayor información de entrada a la red y por lo tanto, se le facilita la construcción interna de las no-linealidades que están afectando la producción del pozo equis.

Figura 42. Modelo SIRMANN tipo I.



Teniendo en cuenta la ecuación de flujo a estado pseudo-estable (ecuaciones 61a y 61b) y el análisis de áreas de drenaje (figura 33), la RNA debería, teóricamente, poder estimar el valor de r_e con los datos de caudales y presiones de fondo.

Figura 43. Modelo SIRMANN tipo II.



La presión promedio del yacimiento debería ser igualmente inferida por el SIRMANN. Sin embargo, puede llegar a ser más efectivo incluir el dato de producción acumulada dentro de las entradas de la RNA.

En la figura 43 se incluye un pozo K inyector, para mostrar cómo se pueden incorporar en el análisis varios tipos de pozos. De la misma manera, se deja abierta la posibilidad de incluir otras variables en cada pozo, tanto en las entradas como en las salidas.

Si se pretende entrenar una RNA para calcular datos estáticos de un pozo nuevo, hay que incluir las coordenadas de posición de los pozos en las variables de entrada (ver figura 44).

Mientras que, cuando lo que se pretende establecer con el SIRMANN es un dato que depende definitivamente del tiempo (de la historia de producción del campo), como por ejemplo el caudal de producción de un nuevo pozo (proyectos de desarrollo del campo), se debe incluir en el entrenamiento una variable que también dependa del tiempo (ver figura 45).

Figura 44. Modelo SIRMANN tipo III.

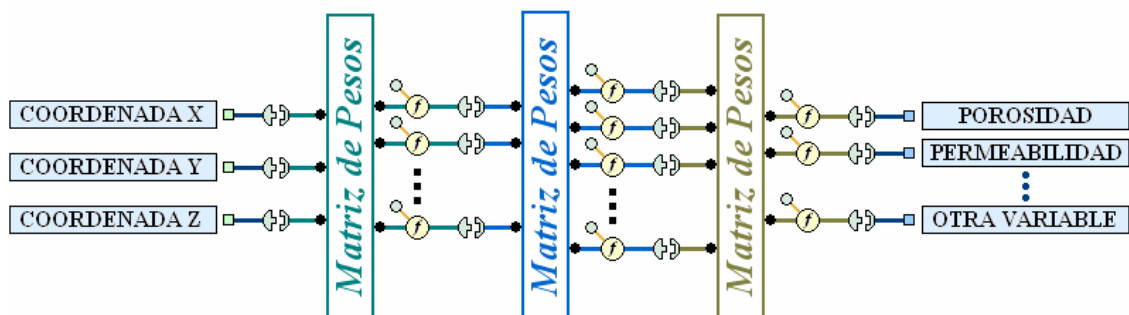
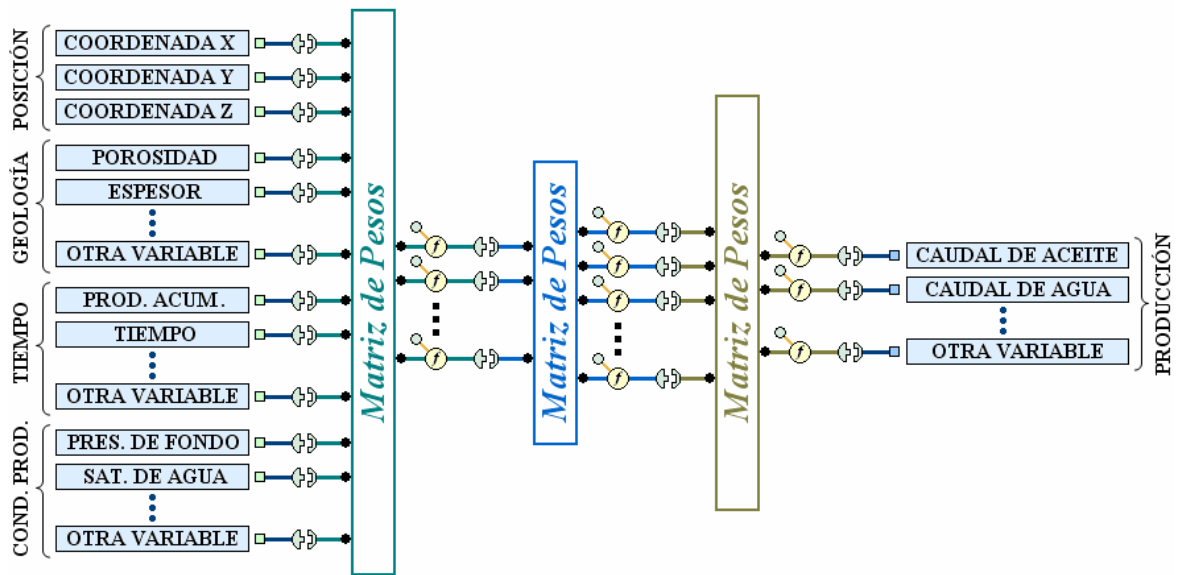


Figura 45. Modelo SIRMANN tipo IV.



4. HEURÍSTICA PARA EL USO DE UN SIRMANN

En este capítulo se presentan algunas recomendaciones para el entrenamiento y uso, del modelo inteligente para la simulación de producción de yacimientos.

Se trata de una serie de pasos que se desarrollaron durante la construcción de la herramienta software de evaluación de los diferentes modelos SIRMANN propuestos hasta el momento.

4.1. SELECCIÓN DEL SOFTWARE

Inicialmente, se programó en Delphi Borland (ésta es una marca comercial de Borland Software Corporation) la red neuronal artificial **feedforward** con entrenamiento **backpropagation**. A pesar de la buena respuesta del programa en términos de tiempo de ejecución y resultados, el algoritmo **backpropagation** en su forma más sencilla está muy limitado, de allí que fue necesario buscar herramientas comerciales que permitieran ejecutar diferentes algoritmos de entrenamiento para RNA. Nota: el código fuente de la aplicación RNA en Delphi se presenta, junto con éste documento, en formato electrónico.

En el mercado se encuentran muchas herramientas para RNA, pero pocas de ellas le permiten al usuario adicionar código. Por ello y por el nivel de desarrollo que tiene la herramienta de redes neuronales artificiales de Matlab (ésta es una marca comercial de Mathworks Inc.), se prefirió éste software frente a los demás, para desarrollar y probar varios SIRMANN.

La primera aplicación que se construyó en Matlab, fue para evaluar individualmente los pozos productores. No obstante, cuando se desarrolló el

código para analizar todos los pozos al mismo tiempo, ésta aproximación inicial se convirtió en un caso particular del segundo software. Por lo tanto, sólo se explica a continuación el caso más general. Como anexo a éste documento se entrega el código en Matlab para la construcción y evaluación de SIRMANN, acompañado de los respectivos videos de ayudas.

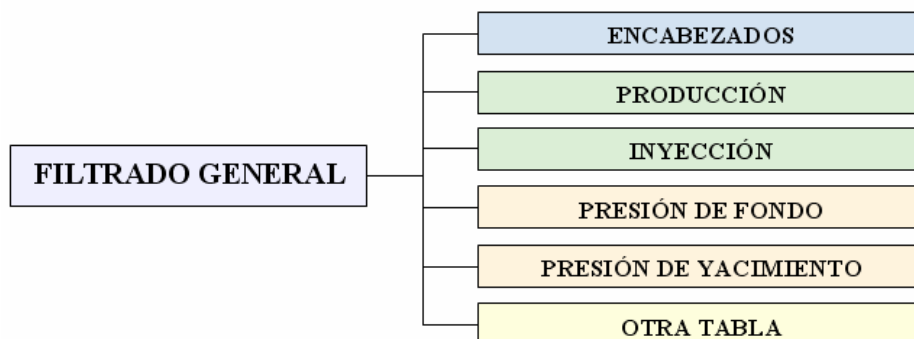
4.2. FILTRADO Y ORGANIZACIÓN DE LOS DATOS

La aplicación se divide en tres partes principales:

- Manejo de los datos a evaluar.
- Definición de variables.
- Construcción, entrenamiento y evaluación del SIRMANN.

En Matlab, el manejo de datos se facilita porque se cuenta con una herramienta para enlazar bases de datos y ejecutar consultas SQL. A pesar de ésta ventaja, fue necesario elaborar código suficiente para facilitar la tarea de filtrado, lectura y escritura de datos.

Figura 46. Esquema general de tablas.



La estructura básica de datos utilizada es bastante sencilla (ver figura 46). El filtrado general se hace en una sola tabla y las demás tablas sólo tienen que hacer el enlace por el identificador único de pozos.

El filtrado general puede construirse con los campos que se muestran en la siguiente tabla:

Tabla 4. Campos y comentarios del filtrado general.

CAMPO	COMENTARIOS
IDENTIFICADOR	Identificador único del pozo. Ej: MAN0001:CABALLOS.
CAMPO	Campo al que pertenece el pozo. Ej: CUSIANA.
TIPO DE POZO	Tipo de pozo. Ej: PRODUCTOR, INYECTOR, etc.
METODO	Tipo de levantamiento artificial. Ej: BM (bombeo mecánico).
ESTADO	Estado del pozo. Ej: INACTIVO, MONITOR, etc.
BATERÍA	Batería a la que llegan los fluidos del pozo. Ej: BATERÍA EL MONAL.
OTRO CAMPO	Cualquier otro campo que se quiera utilizar para el filtrado.

La tabla de encabezados es la que aporta información general del pozo (tabla 5).

Tabla 5. Encabezados del pozo.

CAMPO	COMENTARIOS
IDENTIFICADOR	Identificador único del pozo. Ej: MAN0001:CABALLOS.
XCOOR	Coordenada con respecto al este y el oeste (EASTING).
YCOOR	Coordenada con respecto al norte y el sur (NORTHING).
KBELEVATION	Elevación de la rotaria.
ALIAS	Nombre corto del pozo. Ej: MAN-01.
OTRO CAMPO	Cualquier otro campo que se quiera como encabezado.

El identificador de la tabla 5 no puede parecer más de una vez. Note también que ésta información se espera constante en toda la vida productiva del pozo.

Los datos de producción e inyección tienen un formato similar (ver tabla 6). Cada volumen, producido o inyectado, se reporta a una fecha en particular. Por lo tanto, en condiciones normales para un identificador debería existir una sola fecha de reporte. Sin embargo, y a diferencia de las tablas que se utilizan en los programas comerciales para manejar de datos de producción, se hizo una modificación para poder comparar diferentes corridas de datos y escenarios, adicionando un campo denominado track.

Tabla 6. Campos del reporte de producción o inyección.

CAMPO	COMENTARIOS
IDENTIFICADOR	Identificador único del pozo. Ej: MAN0001:CABALLOS.
DATE	Fecha del reporte de producción/inyección.
DAYS	Días en que el pozo estuvo en producción o en inyección.
OIL	Volumen de aceite producido (no aplica para inyectores).
GAS	Volumen de gas producido (no aplica para inyectores).
WATER	Volumen de agua producida (no aplica para inyectores).
PRESINJ	Presión de inyección (no aplica para productores).
WATINJ	Agua inyectada (no aplica para productores).
TRACK	Identificador de corrida de datos y/o escenarios.

Los datos de presión de fondo fluente y de presión promedia de yacimiento tienen formatos similares (ver tabla 7) pero, deben ser presentados en tablas diferentes, debido a que las fechas de reporte de cada dato no son necesariamente las mismas.

Tabla 7. Campos del reporte de presiones.

CAMPO	COMENTARIOS
IDENTIFICADOR	Identificador único. Ej: MAN0001:CABALLOS.
DATE	Fecha del reporte de producción/inyección.
TRACK	Identificador de corrida de datos y/o escenarios.
Pwf	Presión de fondo fluente (no está en la tabla de presión promedia).
PR	Presión promedia (no está en la tabla de presión de fondo fluente).

Hay que tener presente que, cuando se va a utilizar un SIRMANN, combinando datos de presión y producción, se debe tomar una fecha base (generalmente la de producción) y hacer las extrapolaciones e interpolaciones necesarias, para poder tener todos los datos sobre un mismo rango de fechas.

4.3. DEFINICIÓN DE VARIABLES

La definición de variables es necesaria para que el software pueda saber en qué tablas y en cuáles campos están alojados los datos de aceite, agua, etc.

Con ésta información, se pueden incluir subrutinas para enlazar los datos originales con correlaciones preestablecidas.

Los tipos de variables principales son: días en producción/inyección, volumen de aceite, volumen de agua de producción, volumen de gas, presión del yacimiento, presión de fondo fluyente, presión de fondo de inyección, volumen de agua inyectada, track u otro tipo. Ésta última opción puede utilizarse para definir datos como la permeabilidad o cualquier otro dato del cual no se haya establecido aún, alguna correlación.

Tabla 8. Prefijos para la definición de variables.

Tipo de Dato	Prefijo
Días en producción/inyección.	DIA
Volumen de aceite.	OIL
Volumen de agua de producción.	WAP
Volumen de gas.	GAS
Presión del yacimiento.	PPR
Presión de fondo fluyente.	PWF
Presión de fondo de inyección.	PIN
Volumen de agua inyectada.	WAI
Track.	TRA
Otro tipo.	OTR

El enlace de variables con su tipo puede almacenarse en forma de tabla. Pero, por facilidad, en el software construido se utilizó una sola variable de tipo estructura para guardar todos los enlaces, siguiendo un formato de prefijos y separación por puntos. Los prefijos utilizados se listan en la tabla 8.

El formato de enlace es: **PREFIJO.TABLA.FECHA.CAMPO**. Por ejemplo, si se quiere establecer que el agua de inyección está en la tabla MONTHLYINJ en un campo denominado WATINJ, el enlace es: **WAI.MONTHLYINJ.DATE.WATINJ**. En donde DATE es el nombre del campo que contiene las fechas en la tabla MONTHLYINJ.

4.4. CONSTRUCCIÓN DEL SIRMANN

De las variables definidas con el formato **PREFIJO.TABLA.FECHA.CAMPO**, se eligen las entradas y salidas, designándole el pozo a cada selección. El nuevo formato es **POZO.PREFIJO.TABLA.FECHA.CAMPO**.

En el nuevo formato no se seleccionan las variables tipo track porque éstas son utilizadas posteriormente para elegir el escenario. Tampoco se especifica el tiempo, porque ya está definido por **FECHA**. En éste punto ya deben haberse hecho las interpolaciones y/o extrapolaciones de tiempo necesarias.

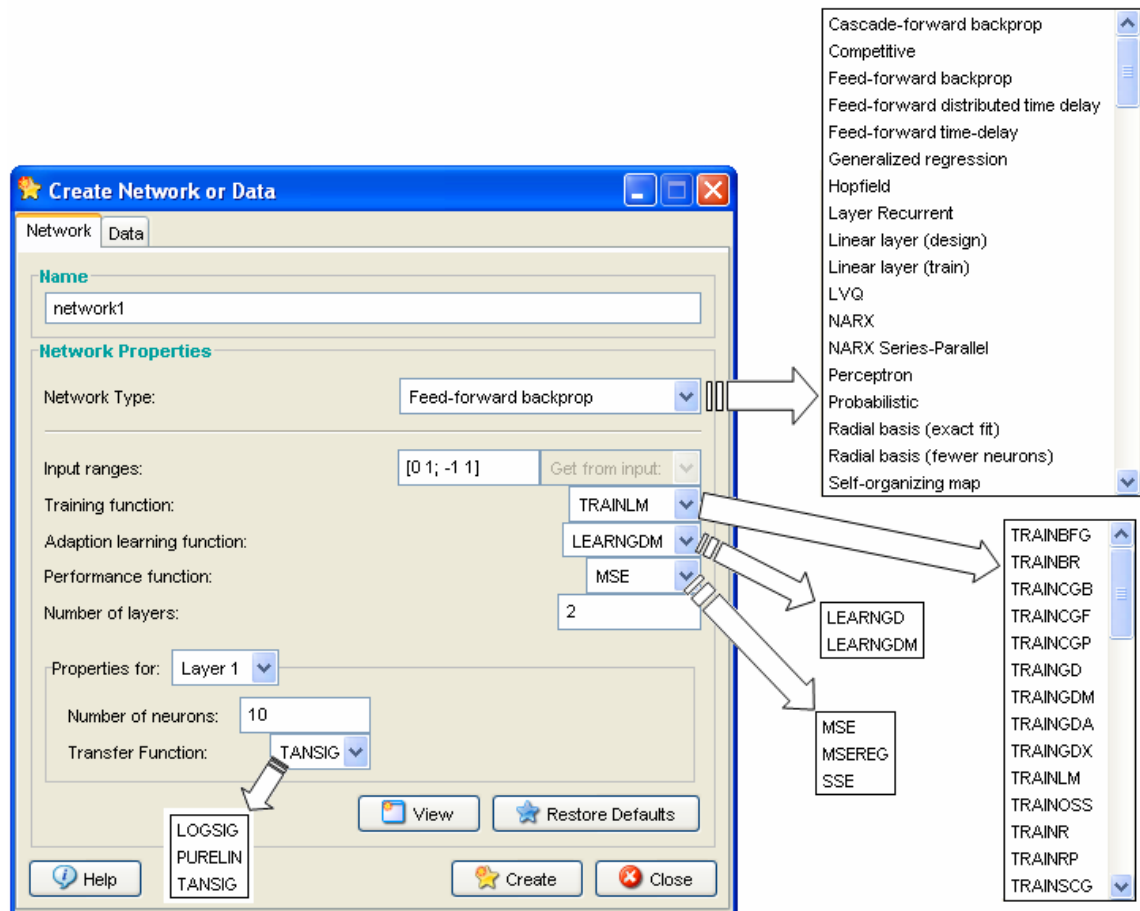
En la tabla 9 se presenta un ejemplo de la definición de entradas y salidas, para una RNA del mismo tipo que se muestra en la figura 36.

Con éste método no es un inconveniente incluir más pozos, dado que solamente se tiene que adicionar un prefijo para sumar una variable. De éste modo se pueden incluir tantas variables como tipos de datos se quiera.

Tabla 9. Ejemplo de definición de variables de entrada y salida.

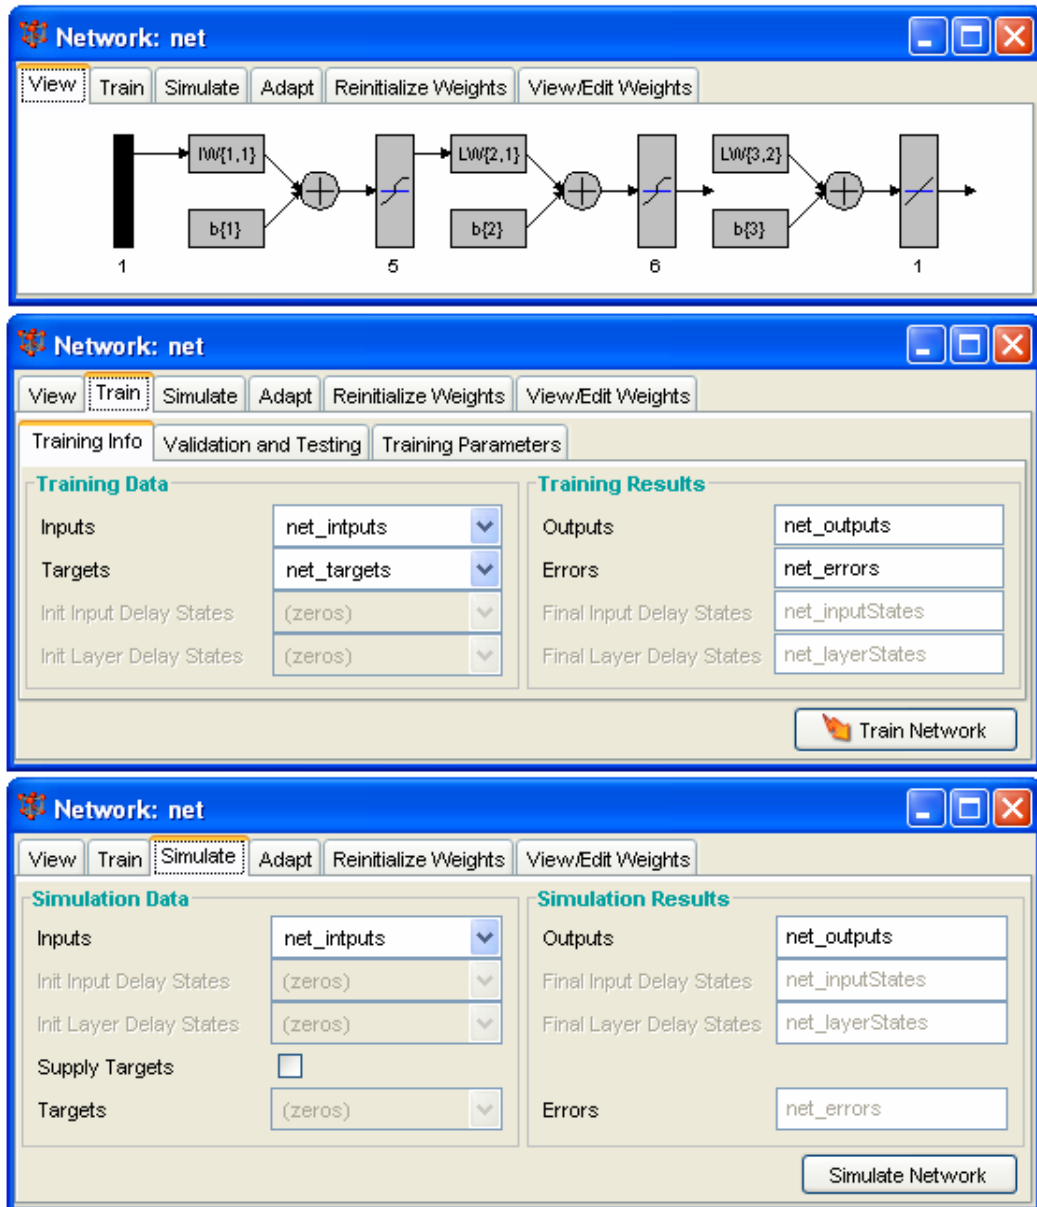
	VARIABLE	TABLA	CAMPO	DEFINICIÓN FINAL
ENTRADA	TIEMPO	---	---	No requiere
	DIAS	MONTHLYPROD	DAYS	VAV0001.DIA.MONTHLYPROD.DATE.DAYS
	Pwf	PRESION_PWF	Pwf	VAV0001.PWF.PRESION_PWF.DATE.Pwf
SALIDA	VOL. ACEITE	MONTHLYPROD	OIL	VAV0001.OIL.MONTHLYPROD.DATE.OIL
	VOL. GAS	MONTHLYPROD	GAS	VAV0001.GAS.MONTHLYPROD.DATE.GAS
	VOL. AGUA	MONTHLYPROD	WATER	VAV0001.WAP.MONTHLYPROD.DATE.WATER

Figura 47. Definición de la RNA con Matlab.



La definición del SIRMANN tiene dos componentes que son la red neuronal artificial y los datos que se ingresan para el entrenamiento y la simulación. La RNA puede definirse (ver figura 47), entrenarse y simularse fácilmente (ver figura 48), con la ayuda de la herramienta de redes de Matlab³⁷.

Figura 48. Entrenamiento y simulación de la RNA con Matlab.



³⁷ DEMUTH, Howard and BEALE Mark. Neural Networks Toolbox. User's Guide. Version 4.

A partir de aquí ya es posible elegir el rango de tiempo disponible, el cual es el conjunto de fechas que tiene datos válidos para todas las variables de entradas y salidas (una operación de intersección).

Tabla 10 (a). Datos iniciales del ejemplo de selección del tiempo disponible.

FECHA	DÍAS	Pwf	VOL. ACEITE	VOL. AGUA	VOL. GAS
1-Feb-04	23	---	510	235	423
1-Mar-04	28	1560	280	425	273
1-Abr-04	30	201.2	387	13	189
1-May-04	30	1335	475	152	219
1-Jun-04	---	1385	---	---	---
1-Jul-04	19	379.3	91	302	95
1-Ago-04	27	---	245	402	376
1-Sep-04	---	1383	---	---	---
1-Oct-04	24	422.6	45	186	323

Para ilustrar la selección de fechas disponibles, se presentan los datos de la tabla 10a. Luego de un filtrado simple, queda la tabla 10b que contiene las filas con los registros que se pueden seleccionar para el entrenamiento y la simulación de la RNA.

Tabla 10 (b). Datos filtrados del ejemplo de selección del tiempo disponible.

FECHA	DÍAS	Pwf	VOL. ACEITE	VOL. AGUA	VOL. GAS
1-Mar-04	28	1560	280	425	273
1-Abr-04	30	201.2	387	13	189
1-May-04	30	1335	475	152	219
1-Jul-04	19	379.3	91	302	95
1-Oct-04	24	422.6	45	186	323

La evaluación de diferentes escenarios se ve apoyada en el uso de las variables tipo track. Por ejemplo, si se entrena una RNA con todos los datos de la tabla 10b y se quiere saber la curva IPR predicha por la RNA a la fecha 01-Jul-2004, se deben incluir dos tracks (ver tabla 11).

Tabla 11. Ejemplo de evaluación de dos escenarios.

FECHA	DÍAS	Pwf	VOL. ACEITE	VOL. AGUA	VOL. GAS	TRACK
1-Mar-04	28	1560	280	425	273	1
1-Abr-04	30	201.2	387	13	189	1
1-May-04	30	1335	475	152	219	1
1-Jul-04	19	379.3	91	302	95	1
1-Oct-04	24	422.6	45	186	323	1
1-Jul-04	19	379.3				2
1-Jul-04	19	316.1				2
1-Jul-04	19	252.9				2
1-Jul-04	19	189.6				2
1-Jul-04	19	126.4				2
1-Jul-04	19	63.2				2
1-Jul-04	19	0				2

Los espacios en blanco de la tabla 11, son aquellos que deben ser llenados con la respuesta de la RNA entrenada con el track 1 y simulada con el track 2.


4.5. ESCALAMIENTO

Las características de la RNA y sus funciones de activación no permiten un buen desempeño si los valores de los datos que se utilizan para el entrenamiento y la simulación están muy lejos del rango de cero a uno.

El efecto del escalamiento no se limita al desempeño de la RNA. El hecho de colocar al mismo nivel de magnitud los datos, hace que cada variable ejerza el mismo peso sobre el SIRMANN y sólo su dispersión va a convertirla en una variable más significativa frente a las demás. Es decir, que no son las variables de mayor magnitud las que dominan el sistema, sino aquellas variables que demuestren que sus fluctuaciones causan mayores cambios en las variables de salida.

Por éste fenómeno es que se dice que no sirve un dato que no cambie (constante) durante el entrenamiento del SIRMANN, porque no le permite a la red percibir su efecto, su peso, su impacto en el sistema. Caso contrario a la simulación clásica, en donde el efecto de una variable sobre el sistema está preestablecido por ecuaciones.

Figura 49. Escalamiento.



El escalamiento que se propone es una relación lineal sencilla, que busca hallar el equivalente de un valor en un nuevo rango (ver figura 49 y ecuaciones 65a y 65b).

$$r = b - \frac{(b-a)(B-R)}{(B-A)} \text{ Ecuación 65a.}$$

$$R = B - \frac{(B-A)(b-r)}{(b-a)} \text{ Ecuación 65a.}$$

Para pasar un conjunto de datos a un rango de cero a uno, se parte de la ecuación 65a, se asignan los valores de $a = 0$ y $b = 1$, y se obtiene la expresión:

$$r = 1 - \frac{(B-R)}{(B-A)} \text{ Ecuación 66.}$$

Los valores de A y B dependen de la variable en estudio. Por ejemplo, para los días se tiene una relación de $A = 0$ y $B = 31$ de acuerdo con los días del mes.

Para las presiones sólo se puede establecer $A = 0$. Lo demás se calcula a partir de los mínimos y máximos resultantes de la unión de los conjuntos de entrenamiento y simulación.

Los valores para A y B de la tabla 11, se presentan en la tabla 12a. La tabla 11 escalada se lista en la tabla 12b.

Para las fechas, es necesario hacer la conversión a formato numérico. En MS Excel, el 01-Mar-2004 equivale a 38047 y el 01-Oct-2004 al número 38261.

Tabla 12(a). Valores de A y B de la tabla 11.

	FECHA	DÍAS	Pwf	VOL. ACEITE	VOL. AGUA	VOL. GAS
A	1-Mar-04	19	0	45	13	95
B	1-Oct-04	30	1560	475	425	323

Tabla 12(b). Datos escalados de la tabla 11.

FECHA	DÍAS	Pwf	VOL. ACEITE	VOL. AGUA	VOL. GAS	TRACK
0.000	0.82	1.00	0.55	1.00	0.78	1
0.145	1.00	0.13	0.80	0.00	0.41	1
0.285	1.00	0.86	1.00	0.34	0.55	1
0.570	0.00	0.24	0.11	0.70	0.00	1
1.000	0.45	0.27	0.00	0.42	1.00	1
0.570	0.00	0.24				2
0.570	0.00	0.20				2
0.570	0.00	0.16				2
0.570	0.00	0.12				2
0.570	0.00	0.08				2
0.570	0.00	0.04				2
0.570	0.00	0.00				2

Para probar la efectividad del escalamiento se corrieron tres redes **feedforward** con entrenamiento **backpropagation** y configuración **1:5:6:3** (ver figura 50). En la figura 51 se muestra la estructura de la red en el formato de Matlab y en el formato general que se presenta en el capítulo primero de éste documento.

Figura 50. Formato de configuración de la RNA.





Figura 51. Estructura de RNA utilizada en el ejemplo del escalamiento.



Las funciones de entrenamiento de las redes utilizadas fueron: regularización bayesiana (TRAINBR), gradiente descendente con momentum (TRAINGDM) y Levenberg-Marquardt (TRAINLM), respectivamente (ver funciones de entrenamiento de la figura 47).

Figura 52 (a). Ejemplo de escalamiento con Regularización Bayesiana.





Figura 53. Ejemplo de escalamiento con Gradiente y Momentum.



Los resultados para el volumen de aceite muestran que la aproximación es mejor cuando se efectúa el escalamiento (ver figuras 52a, 53 y 54a).

Figura 54(a). Ejemplo de escalamiento con Levenberg-Marquardt (aceite).





Figura 54(b). Ejemplo de escalamiento con Levenberg-Marquardt (agua).



El escalamiento con Levenberg-Marquardt funciona muy bien tanto para la interpolación como para la extrapolación. Sin embargo, estos resultados no garantizan que ésta configuración siempre funcione bien. De hecho, para esa misma red, las salidas de agua y gas fueron malas en términos de extrapolación. (Ver figuras 54b y 54c).

Figura 54(c). Ejemplo de escalamiento con Levenberg-Marquardt (gas).






Figura 52(b). Ejemplo de escalamiento con Regularización Bayesiana (agua).



Para la extrapolación hacia adelante de datos escalados, la regularización bayesiana fue el algoritmo que mejor funcionó a nivel general, para las tres fases aceite, agua y gas (ver figuras 52a, 52b y 52c).

Figura 52(c). Ejemplo de escalamiento con Regularización Bayesiana (gas).



5. EVALUACIÓN DE DIFERENTES ESQUEMAS DE SIRMANN

Luego de definidos los pasos para la utilización de las RNA como modelos sustitutos de yacimientos, se presenta éste capítulo dedicado a presentación de los resultados obtenidos para diferentes esquemas SIRMANN.

La estrategia de evaluación consiste en verificar la efectividad de la herramienta SIRMANN, comparando diferentes estructuras y tipos de datos. Buscando que, a medida que se avance, se vaya obteniendo una guía de cuáles RNA son las mejores para cada problema.

Los datos utilizados fueron de dos tipos: reales (campo Vacavieja y campo Yatí) y simulados numéricamente (campo Manguitos). Se tuvo presente cambiar los nombres reales de los pozos, para proteger la confidencialidad de los propietarios de la información.

La simulación numérica se justifica porque, en situaciones reales, no es viable evaluar tantos escenarios como se quiera. Estas simulaciones permiten ponderar de manera más efectiva, la capacidad que puede llegar a tener la red para emular efectivamente las no-linealidades del comportamiento de flujo de los yacimientos.

La primera etapa de evaluación de SIRMANN comenzó con los casos individuales de pozos, incluyendo productores e inyectores. La segunda etapa consistió en incluir varios pozos actuando al mismo tiempo. Aquí, jugó un papel importante la simulación numérica que se hizo en el campo ficticio, buscando comparar el comportamiento simulado con la respuesta de la red. El objetivo fue notar cuán buena era la RNA: demostrar interacciones entre pozos, predecir el comportamiento de producción y ponderar zonas de interés para nuevos pozos.

5.1. CRITERIO DE VALORACIÓN DE LOS RESULTADOS DE LA RNA

Antes de comenzar la evaluación fue necesario definir un parámetro calificador de la respuesta del modelo SIRMANN. Partiendo del coeficiente de determinación y agregando algo de errores relativos, se llegó al factor deseado.

El coeficiente de determinación (r-cuadrado) es visto, normalmente, como un parámetro efectivo para establecer el grado de ajuste de una regresión. Sin embargo, una mirada detallada a la definición de éste factor puede hacer cambiar éste precepto.

Una medida común de la asociación entre dos variables es el coeficiente de correlación³⁸, definido como:

$$r = \frac{n\sum XY - \sum X \sum Y}{\sqrt{[n\sum X^2 - (\sum X)^2][n\sum Y^2 - (\sum Y)^2]}} \quad \text{Ecuación 67.}$$

En donde:

X es el valor de la variable que se supone independiente.

Y es el valor de la variable que se supone dependiente.

n es el número de parejas X, Y .

Si:

$r = 0$, no hay correlación entre X e Y .

$r = +1$, hay correlación positiva perfecta entre X e Y .

$r = -1$, hay correlación negativa perfecta entre X e Y .

$r =$ valores intermedios, la importancia de los valores debe ser considerada.

³⁸ KEENAN, Jhon. Statistical Techniques for Data Analysis. Lewis Publishers, Inc. p. 137- 139.


El cuadrado del coeficiente de correlación, r^2 , denominado coeficiente de determinación, es la cantidad de variación en el término dependiente que puede ser atribuido a la variable independiente.

Éste coeficiente de determinación, debe ser utilizado cuidadosamente para evitar interpretaciones erróneas. Un coeficiente de correlación positivo no implica una relación causal. Pueden existir diferentes razones por la cuales ambos valores cambian de forma similar.

Un ejemplo clásico, citado por Snedecor y Cochran³⁹, muestra un alto grado de correlación negativa entre la tasa de natalidad de Gran Bretaña, desde 1875 y 1920, y la producción anual de fundición de hierro en los Estados Unidos de Norteamérica.

También se cree que el coeficiente de determinación es una medida de la efectividad de un ajuste de datos. Pero, y tal como se muestra en la figura 55, pueden existir situaciones en que diversas regresiones tengan un buen valor de r-cuadrado, indicando erróneamente un apropiado ajuste de datos.

Figura 55. Inconsistencias del r-cuadrado como evaluador de regresiones.



Los datos utilizados para construir la figura 55 están listados en la tabla 13.

³⁹ SNEDECOR, G. W. and COCHRAN, W. G. Statistical methods. 6 ed. Ames. IA: Iowa University Press, 1967. Sect. 7.8. Citado en: KEENAN, Jhon. Statistical Techniques for Data Analysis. Lewis Publishers, Inc. p. 137- 139.

Tabla 13. Datos utilizados para trazar la figura 55.

Datos Originales	Regresión 1	Regresión 2	Regresión 3
10	10	20	5
20	20	30	10
30	30	40	15
40	40	50	20
50	50	60	25
60	60	70	30

Para saber si una RNA se ajusta, bien o mal, a un conjunto de datos originales, se propone un parámetro que tenga en cuenta, además del coeficiente de determinación, el error relativo de los datos aproximados (se descarta el error absoluto porque aquellos datos de mayor magnitud influirían demasiado sobre el resultado).

El factor propuesto parte de que, si se grafican los datos originales versus los aproximados, se debe obtener una línea recta de pendiente igual a uno. Aquellas regresiones que tengan muchos datos cercanos a ésta línea guía (datos con menor porcentaje de error, ver ecuación 68) serán las mejores regresiones.

$$E = \text{abs} \left(\frac{\gamma_r - \gamma_a}{\gamma_r} * 100 \right) \text{ Ecuación 68.}$$

En donde:

E porcentaje de error.

γ_r dato real.

γ_a dato aproximado.

El margen de error se divide en tres grupos de acuerdo con los porcentajes. Adicionalmente, a cada división de le da un peso, de manera que entre más cerca se esté a la línea de interés, mayor será el factor de ajuste (ver ecuación 69).

$$\psi = 0.7 * E_{0-10} + 0.5 * E_{10-20} + 0.3 * E_{20-30} + 0.3 * r^2 \quad \text{Ecuación 69.}$$

En donde:

$$E_{A-B} = \frac{DE_{A-B}}{n} \quad \text{Ecuación 70.}$$


Siendo:

DE_{A-B} el número de datos que tienen un porcentaje de error mayor que A y menor o igual a B .

n el número total de datos.

Los resultados del nuevo factor de ajuste se muestran en la figura 56.

Figura 56. Factores de ajuste para los datos de la tabla 13.



Note que, en este ejemplo, el nuevo parámetro pondera mejor la calidad del ajuste de las regresiones.

5.2. ESQUEMA RNA PARA UN SOLO POZO

Los primeros modelos de RNA evaluados, fueron aquellos que toman solamente datos de un pozo y dejan a la red, la tarea de aprender el resto de relaciones entre el pozo en estudio y el yacimiento.

Por convención, el área sombreada de azul de las gráficas, representa el sector de los datos del entrenamiento de la RNA. En consecuencia, la zona amarilla es la de interpolación y/o extrapolación.

5.2.1. DECLINACIÓN SIMPLE

Se define declinación simple como aquella que se construye solamente a partir del tiempo y del caudal de aceite (ver figura 34). Para su evaluación, se utilizaron datos de tres pozos: VAV-01, VAV-02 y MAN-04. El primer pozo tiene un comportamiento exponencial y los demás siguen una tendencia hiperbólica.

Tres tipos de RNA **feedforward backpropagation** fueron probadas: regularización bayesiana (TRAINBR), gradiente con momentum (TRAINGDA) y Levenberg-Marquardt (TRAINLM). Los resultados para el pozo VAV-01, en términos del factor de ajuste, se muestran en las tablas 14a, 14b y 14c.

Tabla 14 a. Declinación Simple en TRAINBR, pozo VAV-01.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINBR	1:10:1	0.9435	0.8264
	1:2:1	0.9208	0.9162
	1:2:2:1	0.9206	0.9158
	1:4:1	0.9207	0.9162
	1:4:5:1	0.9206	0.9210
	1:6:5:1	0.9207	0.9154

Tabla 14(b). Declinación Simple en TRAINGDA, pozo VAV-01.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINGDA	1:10:1	0.2107	0.2249
	1:2:1	0.8548	0.7226
	1:2:2:1	0.5701	0.5006
	1:4:1	0.8991	0.7283
	1:4:5:1	0.6423	0.4163
	1:6:5:1	0.3943	0.3509

Tabla 14(c). Declinación Simple en TRAINLM, pozo VAV-01.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINLM	1:10:1	0.9439	0.7545
	1:2:1	0.9207	0.9153
	1:2:2:1	0.9123	0.8674
	1:4:1	0.9224	0.9256
	1:4:5:1	0.9211	0.8175
	1:6:5:1	0.9440	0.5033

Los mejores resultados de extrapolación se obtuvieron para la regularización bayesiana (ver figura 57). También se puede apreciar que el entrenamiento con la función TRAINGDA es el peor para hacer predicciones (ver figura 58).

Figura 57. Declinación Simple, TRAINBR, configuración 1:4:5:1, VAV-01.






Figura 58. Declinación Simple, TRAINGDA, configuración 1:4:1, pozo VAV-01.



Para la función de entrenamiento TRAINLM, se encuentra que las estructuras más sencillas (1:2:1 y 1:4:1) son las que muestran mejor respuesta de red (figura 59).

Figura 59. Declinación Simple, TRAINLM, configuración 1:2:1, pozo VAV-01.



El segundo caso de declinación simple evaluado es el de comportamiento hiperbólico, tomado del pozo VAV-02. Este pozo se caracteriza por no tener una

tendencia clara (ver figura 60), lo que dificulta el trabajo de la RNA. Ésta situación no sería un problema para el modelo de declinación de Arps.

Los resultados para VAV-02 se presentan en las tablas 15a, 15b y 15c.

Tabla 15(a). Declinación Simple en TRAINBR, pozo VAV-02.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINBR	1:10:1	0.9993	0.2305
	1:2:1	0.7756	0.2398
	1:2:2:1	0.8931	0.1636
	1:4:1	0.8869	0.1144
	1:4:5:1	0.8907	0.2032
	1:6:5:1	0.9819	0.1120

Tabla 15(b). Declinación Simple en TRAINGDA, pozo VAV-02.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINGDA	1:10:1	0.2877	0.0044
	1:2:1	0.3364	0.3498
	1:2:2:1	0.4382	0.1956
	1:4:1	0.5615	0.0441
	1:4:5:1	0.3620	0.2628
	1:6:5:1	0.3187	0.2492

Tabla 15(c). Declinación Simple en TRAINLM, pozo VAV-02.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINLM	1:10:1	1.0000	0.0032
	1:2:1	0.8945	0.6001
	1:2:2:1	0.8947	0.2073
	1:4:1	0.8934	0.0792
	1:4:5:1	0.9810	0.3375
	1:6:5:1	0.9996	0.2402

Se tuvo un buen ajuste con la configuración 1:2:1 en TRAINLM. Sin embargo, la predicción muestra un caudal constante y tal situación es inconsistente con la tendencia de producción de los pozos petrolíferos. Estos resultados pobres se presentan porque en VAV-02, se tienen oscilaciones del caudal que “confunden” a la RNA. Es por eso que otras variables, como la presión, deben ser incluidas para que la red encuentre una nueva relación que explique mejor, las fluctuaciones particulares que se pueden presentar en los caudales.

Figura 60. Declinación Simple, TRAINBR, configuración 1:2:1, VAV-02.




Figura 61. Declinación Simple, TRAIINGDA, configuración 1:2:1, pozo VAV-02.





Figura 62. Declinación Simple, TRAINLM, configuración 1:2:1, pozo VAV-02.



El último ejemplo de declinación simple evaluado corresponde al pozo MAN-04, un pozo que por ser el resultado de una simulación, prácticamente no contiene ruido alguno. Por tal razón, las respuestas de la red son particularmente exactas (ver tablas 16a y 16c y figuras 63 y 65).

Tabla 16(a). Declinación Simple en TRAINBR, pozo MAN-04.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINBR	1:10:1	0.9999	0.6672
	1:2:1	0.9998	0.9996
	1:2:2:1	0.9998	0.9998
	1:4:1	0.9999	0.5896
	1:4:5:1	0.9999	0.7105
	1:6:5:1	0.9999	0.5442

Tabla 16(b). Declinación Simple en TRAINGDA, pozo MAN-04.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINGDA	1:10:1	0.9366	0.0679
	1:2:1	0.7997	0.2862
	1:2:2:1	0.8700	0.3276
	1:4:1	0.6217	0.1700
	1:4:5:1	0.6279	0.5903
	1:6:5:1	0.6094	0.4291

Tabla 16(c). Declinación Simple en TRAINLM, pozo MAN-04.

Red	Configuración	Ajuste al conjunto de entrenamiento	Ajuste al conjunto de extrapolación/interpolación
TRAINLM	1:10:1	0.9999	0.6672
	1:2:1	0.9998	0.9996
	1:2:2:1	0.9998	0.9998
	1:4:1	0.9999	0.5896
	1:4:5:1	0.9999	0.7105
	1:6:5:1	0.9999	0.5442

Figura 63. Declinación Simple, TRAINBR, configuración 1:2:2:1, MAN-04.






Figura 64. Declinación Simple, TRAINGDA, configuración 1:4:5:1, MAN-04.




Nuevamente la respuesta de la red en TRAINGDA es la peor (ver figura 64). Ésta red no logró, incluso, un buen ajuste de los datos de entrenamiento.

Figura 65. Declinación Simple, TRAINLM, configuración 1:2:2:1, MAN-04.



No todos los resultados de RNA en TRAINBR y TRAINLM, fueron favorables para MAN-04. Algunas proyecciones fueron pésimas (ver figura 66). Lo que conlleva a inferir que se cuenta con exactitud, pero no necesariamente con precisión, cuando se selecciona un tipo de entrenamiento.

Figura 66. Declinación Simple, TRAINBR, configuración 1:4:1, MAN-04.



5.2.2. DECLINACIÓN CON DIVISIÓN DE DÍAS Y VOLUMEN

Como la producción de un pozo se reporta, no por caudales sino por volumen producido y días en producción, se efectúa la división del caudal en éstas dos variables (ver figura 35). Esto se hace con el objetivo de empezar a añadir información, en la búsqueda de un mejoramiento en la declinación de la RNA.

A partir de éste punto, sólo se evalúan las redes que mejores resultados presentan. Por lo tanto, se dejan de lado las RNA de entrenamiento de tipo TRAINGDA y las configuraciones **1:10:1** y **1:6:5:1** del entrenamiento TRAINBR y TRAINLM.

Para apreciar la capacidad de extrapolación dimensional de la RNA, se hace un entrenamiento con datos normales, pero se corre la simulación incluyendo datos de días en producción iguales a cero. Si la RNA es entrenada correctamente, a menos días de producción, la respuesta de la RNA debe ser de menor valor de producción (para días iguales a cero, la producción debe ser cero).

Los datos utilizados en éste ejemplo corresponden a la producción de MAN-03. En las tablas 17a y 17b se presentan los valores de ajustes obtenidos por la red.

Tabla 17(a). Declinación tipo II en TRAINBR, pozo MAN-03.

Red	Configuración	Ajuste al entrenamiento	Ajuste a la extrapolación	Ajuste a la extrapolación con días = 0
TRAINBR	2:2:1	0.9998	0.9708	0.6403
	2:2:2:1	0.9999	0.9701	0.6175
	2:4:1	0.9998	0.8906	0.6028
	2:4:5:1	0.9996	0.9910	0.6468

Tabla 17(b). Declinación tipo II en TRAINLM, pozo MAN-03.

Red	Configuración	Ajuste al entrenamiento	Ajuste a la extrapolación	Ajuste a la extrapolación con días = 0
TRAINLM	2:2:1	0.9998	0.9420	0.6263
	2:2:2:1	0.9999	0.5224	0.5736
	2:4:1	0.9998	0.9595	0.6333
	2:4:5:1	0.9996	0.9831	0.5783

En general, los resultados corresponden con el fenómeno esperado físicamente (a menos días de producción, menor volumen producido).

Figura 67. Declinación tipo II, TRAINBR, configuración 2:2:1, MAN-03.






Figura 68. Declinación tipo II, TRAINLM, configuración 2:4:1, MAN-03.



Incluso la simulación de días iguales a cero (ver figuras 67 y 68) se acerca al valor esperado, excepto para la configuración TRAINLM **2:4:5:1**, que a pesar de tener un buen pronóstico de volúmenes en el tiempo, tiene una mala predicción variando los días producidos (ver figura 69).

Figura 69. Declinación tipo II, TRAINLM, configuración 2:4:5:1, MAN-03.



Una alternativa para mejorar el comportamiento de la RNA, consiste en adicionar información acerca del modelo subyacente. Por ejemplo, si ya se conoce de antemano que para cero días de producción se tiene cero en volumen producido, sólo hay que colocar ese tipo de parejas dentro del conjunto de entrenamiento. Esto es muy útil porque, sin tener que leer más datos de campo, se adiciona información a la RNA y se mejora su respuesta. Los valores de ajuste se presentan en las tablas 18a y 18b.

Tabla 18(a). Declinación tipo II en TRAINBR, pozo MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).

Red	Configuración	Ajuste a la producción normal	Ajuste a la producción normal y la de días = 0
TRAINBR	2:2:1	0.9441	0.6283
	2:2:2:1	0.9253	0.6099
	2:4:1	0.9969	0.6497
	2:4:5:1	0.9768	0.6409

Tabla 18(b). Declinación tipo II en TRAINLM, pozo MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).

Red	Configuración	Ajuste a la producción normal	Ajuste a la producción normal y la de días = 0
TRAINLM	2:2:1	0.9046	0.6161
	2:2:2:1	0.9245	0.6162
	2:4:1	0.9968	0.6497
	2:4:5:1	0.9541	0.6385

Figura 70. Declinación tipo II, TRAINBR, configuración 2:4:1, MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).





Figura 71. Declinación tipo II, TRAINLM, configuración 2:4:1, MAN-03. (Incluyendo en el entrenamiento volumen cero a días cero).



En las figuras 70 y 71 se ilustran los mejores resultados que se obtuvieron incluyendo la restricción de volumen cero de producción a cero días de producción.

Es de notar que, con respecto a la variación de los días de producción, los resultados que arrojan las redes fueron buenos en todos los casos.

5.2.3. DECLINACIÓN CON PRESIÓN DE FONDO


Si a un pozo se le modifica la presión de fondo, por ejemplo por cambios en el sistema de levantamiento, se alterará inmediatamente la producción. Por eso se espera que, para que la RNA emule el efecto del sistema de levantamiento, se debe incluir la presión de fondo fluyente en el conjunto de variables de entrada.

Hay que tener presente que una modificación en la presión de fondo fluyente tendrá efectos tanto a mediano como a largo plazo (aceleración del daño de formación, migración de finos, intrusiones de agua, aumento de la relación gas-aceite, depleción mayor, influencias en otros pozos, entre otros). Por ello se efectúa la evaluación contra el IPR y contra los resultados del simulador numérico.

Para probar el modelo RNA de la figura 36, se simularon dos condiciones de yacimiento, en donde lo único que se modificó, entre escenarios, fue la presión de fondo fluyente.

Primero se entrena la red con un conjunto de datos de presión de fondo del pozo MAN-03 (figura 72) y luego se prueba con el segundo conjunto, para establecer si la RNA es capaz de emular los que arroja el simulador numérico.

Figura 72. Conjuntos de presión de fondo para evaluar la declinación tipo III.



En los resultados que se presentan en las tablas 19a y 19b, se nota que la RNA logró resultados muy similares a los obtenidos con el simulador numérico.

Tabla 19(a). Declinación tipo III en TRAINBR, pozo MAN-03.

Red	Config.	Salida	Datos originales		Datos de simulación	
			Sin caudal igual a cero	Con caudal igual a cero	Sin caudal igual a cero	Con caudal igual a cero
TRAINBR	3:2:3	Gas	0.9028	0.6411	0.9304	0.6417
		Aceite	0.9028	0.6411	0.9304	0.6417
		Agua	0.8215	0.5824	0.8242	0.5722
	3:2:2:3	Gas	0.9024	0.6411	0.9302	0.6416
		Aceite	0.9024	0.6411	0.9303	0.6416
		Agua	0.8250	0.5837	0.8070	0.5636
	3:4:3	Gas	0.9048	0.6413	0.9328	0.6421
		Aceite	0.9048	0.6413	0.9328	0.6421
		Agua	0.8500	0.5955	0.8736	0.5989
	3:4:5:3	Gas	0.9054	0.6413	0.9322	0.6420
		Aceite	0.9054	0.6413	0.9322	0.6420
		Agua	0.8522	0.5959	0.8799	0.6017

A nivel general, las mejores configuraciones fueron las del entrenamiento en regularización bayesiana, porque se ajustó mejor a los datos originales y a los

supuestos con caudal igual a cero. El entrenamiento de tipo Levenberg-Marquardt mostró algunas oscilaciones y menos estabilidad en los resultados.

Tabla 19(b). Declinación tipo III en TRAINLM, pozo MAN-03.

Red	Config.	Salida	Datos originales		Datos de simulación	
			Sin caudal igual a cero	Con caudal igual a cero	Sin caudal igual a cero	Con caudal igual a cero
TRAINLM	3:2:3	Gas	0.9173	0.6370	0.9346	0.6018
		Aceite	0.9173	0.6370	0.9346	0.6017
		Agua	0.8132	0.5756	0.7856	0.5461
	3:2:2:3	Gas	0.8766	0.6267	0.8610	0.6060
		Aceite	0.8765	0.6267	0.8611	0.6060
		Agua	0.7562	0.5426	0.7298	0.5290
	3:4:3	Gas	0.9258	0.6366	0.9376	0.6324
		Aceite	0.9258	0.6366	0.9276	0.6324
		Agua	0.8946	0.6057	0.7629	0.5415
	3:4:5:3	Gas	0.9384	0.6396	0.9519	0.6396
		Aceite	0.9384	0.6396	0.9519	0.6396
		Agua	0.8804	0.5987	0.7715	0.5427

La similitud entre el ajuste al gas y al aceite (ver figuras 73a y 73b), se explica porque la relación gas-aceite se mantiene prácticamente constante en los resultados que arroja el simulador.

Figura 73(a). Declinación tipo III, TRAINBR, 3:4:3, MAN-03, aceite.




Figura 73(b). Declinación tipo III, TRAINBR, 3:4:3, MAN-03, gas.




Figura 73(c). Declinación tipo III, TRAINBR, 3:4:3, MAN-03, agua.




Figura 74(a). Declinación tipo III, TRAINLM, 3:4:5:3, MAN-03, aceite.




Figura 74(b). Declinación tipo III, TRAINLM, 3:4:5:3, MAN-03, gas.





Figura 74(c). Declinación tipo III, TRAINLM, 3:4:5:3, MAN-03, agua.



Con los datos del pozo VAV-01 se prueba la efectividad de la declinación tipo III para extrapolar datos en el tiempo (tablas 20a y 20b, y figuras 75a y 75b) y para emular curvas IPR (figuras 76a, 76b, 77a y 77b).

Tabla 20(a). Declinación tipo III en TRAINBR, pozo VAV-01.

Red	Config.	Datos originales		Datos de simulación	
		Sin caudal igual a cero	Con caudal igual a cero	Sin caudal igual a cero	Con caudal igual a cero
TRAINBR	3:2:1	0.9285	0.6328	0.5645	0.4643
	3:2:2:1	0.9309	0.6329	0.6444	0.5002
	3:4:1	0.9316	0.6330	0.7070	0.5299
	3:4:5:1	0.9315	0.6330	0.6930	0.5225

Tabla 20(b). Declinación tipo III en TRAINLM, pozo VAV-01.

Red	Config.	Datos originales		Datos de simulación	
		Sin caudal igual a cero	Con caudal igual a cero	Sin caudal igual a cero	Con caudal igual a cero
TRAINLM	3:2:1	0.9314	0.6330	0.6744	0.5152
	3:2:2:1	0.9314	0.6330	0.6609	0.5078
	3:4:1	0.9511	0.6407	0.6536	0.5099
	3:4:5:1	0.9667	0.6448	0.3272	0.3826

Figura 75(a). Declinación tipo III, TRAINBR, 3:4:1, VAV-01.




Figura 75(b). Declinación tipo III, TRAINLM, 3:4:1, VAV-01.




Figura 76(a). IPR por declinación tipo III, TRAINBR, VAV-01, 01-Dic-2003.




Figura 76(b). IPR por declinación tipo III, TRAINBR, VAV-01, 01-Ago-2006.




Figura 77(a). IPR por declinación tipo III, TRAINLM, VAV-01, 01-Dic-2003.





Figura 77(b). IPR por declinación tipo III, TRAINLM, VAV-01, 01-Ago-2006.



La RNA en entrenamiento de regularización bayesiana se presenta más estable para el cálculo del IPR, incluso en la fecha de agosto de 2006 que se encuentra por fuera del conjunto de entrenamiento. Ésta red no muestra aún la curvatura esperada, pero respeta el principio físico de que a menos presión de fondo, más caudal de aceite.

Los IPR de regularización bayesiana presentan menos error cuando la presión de fondo se acerca a cero, que cuando se acerca a la presión promedio del yacimiento. Aunque ésta no es la condición ideal, para aumentar el caudal es más

factible que se busque la reducción de la presión de fondo, por lo que la red trabajaría bien en la zona de interés.

Como el principio de la presión de fondo fluuyente es equivalente al de presión de inyección, se aplica una última prueba a la declinación tipo III, para probar la respuesta de una RNA a los datos del pozo inyector MAN-07. Los resultados se muestran en las tablas 21a y 21b y en las figuras 76a y 76b.

Tabla 21(a). Declinación tipo III en TRAINBR, pozo MAN-07.

Red	Configuración	Datos originales	Datos de simulación
TRAINBR	3:2:3	0.5584	0.5964
	3:2:2:3	0.5611	0.6095
	3:4:3	0.5622	0.5657
	3:4:5:3	0.5642	0.6004

Tabla 21(b). Declinación tipo III en TRAINBR, pozo MAN-07.

Red	Configuración	Datos originales	Datos de simulación
TRAINLM	3:2:3	0.5391	0.7481
	3:2:2:3	0.5550	0.6713
	3:4:3	0.5641	0.6359
	3:4:5:3	0.5590	0.5866

Figura 78(a). Declinación tipo III, TRAINBR, 3:2:2:1, MAN-07.





Figura 78(b). Declinación tipo III, TRAINLM, 3:2:1, MAN-07.



La RNA no logra copiar perfectamente los valores de los caudales de inyección. Sin embargo, sí simula la tendencia, porque cuando el caudal aumenta en los datos originales, también sucede lo mismo en los resultados de la RNA.

5.2.4. DECLINACIÓN CON PRESIÓN DE FONDO Y CAUDALES EN LAS ENTRADAS

La evaluación de la estructura de la figura 37 deja resultados claros con respecto a la interpretación que hacen las RNA de los datos utilizados para su entrenamiento.

Al adicionar una entrada de volumen de agua y ejecutar dos diferentes escenarios (ver figura 79), se esperaría que la simulación con un volumen de agua menor producido, dejaría un mayor volumen de aceite producido por efecto de permeabilidades relativas. No obstante, los resultados obtenidos al utilizar los datos del pozo VAV-03 muestran que la RNA encuentra una relación directa entre el volumen de agua y crudos producidos (ver figuras 80a y 80b). Este resultado permite concluir que los volúmenes producidos no deben incluirse como variables de entrada en la RNA, para el análisis de un solo pozo; porque la red interpreta lógicamente que con una disminución del flujo total de líquido, ambas fases reducen su volumen producido.

Figura 79. Escenarios evaluados en VAV-03.




Figura 80(a). Declinación tipo IV, TRAINBR, VAV-03.





Figura 80(b). Declinación tipo IV, TRAINLM, VAV-03.



5.2.5. ESQUEMA GENERAL PARA UN SOLO POZO

Para terminar la revisión de variables comunes para un solo pozo, haría falta incluir la presión promedio del yacimiento.

Con éste nuevo esquema se podría reevaluar la respuesta de la RNA al cálculo del IPR, por lo que se vuelve al ejemplo de los datos del pozo VAV-01. Pero, en ésta ocasión, además de incluir la presión promedio, se suman a los datos de entrada, el principio que garantiza que si no existe caída de presión, no existe flujo. Por lo tanto, para datos de presión de fondo fluyente y promedias iguales, los volúmenes producidos se igualan a cero.

Tabla 22(a). Declinación tipo V en TRAINBR, pozo VAV-01.

Red	Config.	Datos originales	Datos de simulación
TRAINBR	4:2:1	0.4087	0.3677
	4:2:2:1	0.4099	0.3382
	4:4:1	0.4104	0.3649
	4:4:5:1	0.4102	0.3569

Tabla 22(b). Declinación tipo V en TRAINLM, pozo VAV-01.

Red	Config.	Datos originales	Datos de simulación
TRAINLM	4:2:1	0.4099	0.3399
	4:2:2:1	0.4100	0.3393
	4:4:1	0.4116	0.3629
	4:4:5:1	0.4090	0.3662

Comparando los resultados de las figuras 82a y 76a, se concluye que la inclusión de la nueva restricción de presiones mejora el IPR de la RNA en el rango de fechas de interpolación (Abr-2003 -> Jun-2005). Sin embargo, en el rango de presión cercano a cero aún se tiene incertidumbre.

Figura 81(a). Declinación tipo V, TRAINBR, 4:4:1, VAV-01.




Figura 81(b). Declinación tipo V, TRAINLM, 4:4:1, VAV-01.




Figura 82(a). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Dic-2003.

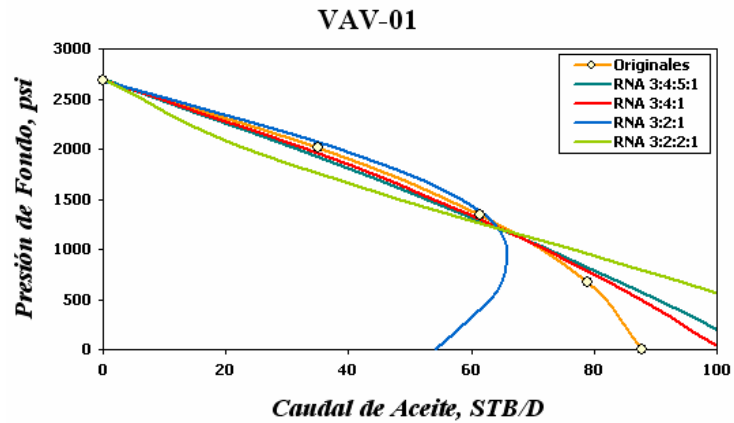


Figura 82(b). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Ago-2006.




Figura 83(a). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Dic-2003.





Figura 83(b). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Ago-2006.



Para completar el IPR, se pueden incluir datos derivados de la ecuación de Vogel, de manera que quede totalmente restringida la respuesta de la RNA.

Es de notar que ninguna de las restricciones sugeridas hasta el momento, requiere de la lectura de nuevos datos de campo.

Figura 84(a). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Dic-2003. (Sumando puntos IPR según Vogel)




Figura 84(b). IPR por declinación tipo V, TRAINBR, VAV-01, 01-Ago-2006. (Sumando puntos IPR según Vogel)

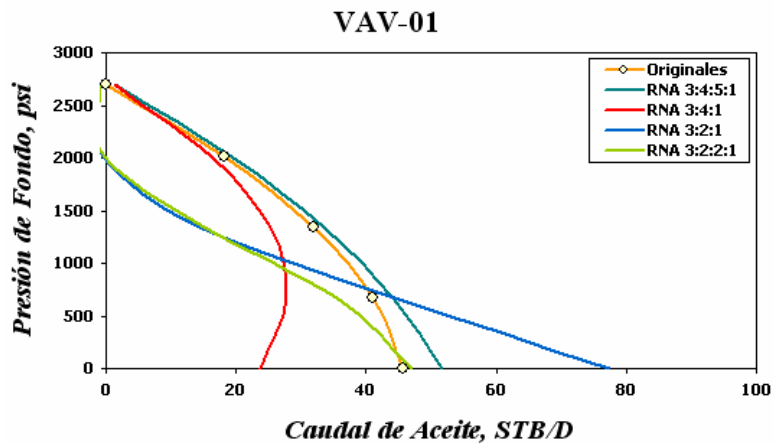


Figura 85(a). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Dic-2003.
(Sumando puntos IPR según Vogel)





Figura 85(b). IPR por declinación tipo V, TRAINLM, VAV-01, 01-Ago-2006.
(Sumando puntos IPR según Vogel)



5.3. ESQUEMA RNA PARA VARIOS POZOS

Cuando existe una interferencia muy marcada entre pozos productores y/o inyectores, no es suficiente con hacer simulaciones partiendo de información para un solo pozo.

Para poder explotar la mayor cantidad de información de un campo, se tienen los esquemas SIRMANN propuestos en la sección 3.2. Estos modelos de RNA, fueron diseñados para encontrar relaciones entre las variables que afectan simultáneamente la producción de varios pozos de un campo, con el objetivo de encontrar información que de otra manera, por ejemplo por simulación numérica, costaría mucho tiempo y dinero.

En ésta sección se presentan los resultados de las pruebas hechas en varios modelos de SIRMANN, para los datos del campo ficticio Manguitos y para el campo real Yatí (nombre modificado para preservar la confidencialidad de los propietarios del campo).

5.3.1. SIRMANN TIPO I

El esquema SIRMANN tipo I (figura 42) es el que utiliza datos de tiempo, días en producción y presiones de fondo, para inferir los volúmenes de producción. De acuerdo con ésta definición, los primeros tres tipos de declinación presentados en la sección anterior, son un caso particular de éste primer tipo de SIRMANN.

Como variables de entrada y salida se tomarán los datos de los pozos MAN-01, MAN-03 y MAN-04, que se encuentran en el sector norte del campo Manguitos. Pero, para la evaluación sólo se utilizarán los cambios en la presión de fondo fluyente del pozo MAN-03 (ver figura 72), de manera que la respuesta de la red será aceptable si se ajusta a los resultados del simulador numérico.

La respuesta del modelo SIRMANN tipo I a la prueba del cambio en la presión de fondo, es muy buena. Sólo a excepción de la configuración **7:2:2:3** en TRAINLM, las RNA dan valores de ajuste superiores a 0.96 (ver tablas 23a y 23b).

Tabla 23(a). SIRMANN tipo I en TRAINBR.

Red	Config.	Salida (aceite)	Datos originales	Datos de simulación
TRAINBR	7:2:3	MAN-01	0.9981	0.9938
		MAN-03	0.9861	0.9811
		MAN-04	0.9925	0.9799
	7:2:2:3	MAN-01	0.9981	0.9931
		MAN-03	0.9861	0.9814
		MAN-04	0.9925	0.9798
	7:4:3	MAN-01	0.9994	0.9994
		MAN-03	0.9962	0.9961
		MAN-04	0.9973	0.9973
	7:4:5:3	MAN-01	0.9995	0.9988
		MAN-03	0.9963	0.9954
		MAN-04	0.9973	0.9969

Tabla 23(b). SIRMANN tipo I en TRAINLM.

Red	Config.	Salida (aceite)	Datos originales	Datos de simulación
TRAINLM	7:2:3	MAN-01	0.9981	0.9927
		MAN-03	0.9861	0.9814
		MAN-04	0.9941	0.9816
	7:2:2:3	MAN-01	0.7978	0.7624
		MAN-03	0.9863	0.9687
		MAN-04	0.9645	0.9553
	7:4:3	MAN-01	0.9994	0.9994
		MAN-03	0.9963	0.9958
		MAN-04	0.9977	0.9974
	7:4:5:3	MAN-01	0.9992	0.9985
		MAN-03	0.9963	0.9965
		MAN-04	0.9975	0.9972

Éste resultado es importante desde dos puntos de vista. El primero es que se ajustan los valores al caudal de MAN-03 y el segundo es que se logra que la RNA no altere la producción de los demás pozos (MAN-01 y MAN-04) al modificar la presión de fondo de MAN-03.

En las figuras 86a y 86b se muestran los mejores resultados obtenidos en la evaluación del modelo SIRMANN tipo I.

Figura 86(a). SIRMANN tipo I, TRAINBR, 7:4:3, MAN-03.





Figura 86(b). SIRMANN tipo I, TRAINLM, 7:4:5:3, MAN-03.



5.3.2. SIRMANN TIPO II

De acuerdo con la simulación numérica, el pozo MAN-03 está influenciado por el pozo inyector MAN-07. Por lo tanto, para probar el modelo SIRMANN tipo II se toman como entradas de la RNA los datos de inyección de MAN-07 (presión de inyección, caudal de inyección, días en inyección), los datos de producción de MAN-03 (presión de fondo fluyente y los días en producción) y los datos de producción de MAN-05 (presión de fondo fluyente y los días en producción). Éste último pozo se encuentra alejado de MAN-07, y se coloca para hacer control de calidad en la respuesta de la RNA.

Se probaron dos escenarios en los que sólo se modificaron las condiciones de inyección de MAN-07. Luego, se comparó la respuesta de la RNA con los resultados de la simulación numérica (ver tablas 24a y 24b y figuras 87a y 87b).

Tabla 24(a). SIRMANN tipo II en TRAINBR.

Red	Configuración	Factor de ajuste total
TRAINBR	8:2:2	0.9883
	8:2:2:2	0.9635
	8:4:2	0.9613
	8:4:5:2	0.6616

Tabla 24(b). SIRMANN tipo II en TRAINBR.

Red	Configuración	Factor de ajuste total
TRAINLM	8:2:2	0.9637
	8:2:2:2	0.9463
	8:4:2	0.9294
	8:4:5:2	0.9709

Figura 87(a). SIRMANN tipo II, TRAINBR, 8:4:2, MAN-03.





Figura 87(b). SIRMANN tipo II, TRAINLM, 8:4:5:2, MAN-03.



Aunque en los parámetros de ajuste de las tablas 23a y 23b, parezca que el ajuste es bueno, la RNA no emuló, en ninguna de las configuraciones evaluadas, la relación entre la inyección de agua en MAN-07 y la producción de aceite en el pozo MAN-03. Una explicación para ésta situación, es que la RNA no tiene suficiente información para inferir tal relación.


En los casos en que la relación de variables es clara y directa, como cuando se modifica la presión de fondo fluyente y se monitorea el caudal, la RNA ha demostrado ser capaz de encontrar una relación apropiada entre las variables. Sin embargo, cuando la relación es sutil y cuando el efecto de una variable sobre otra tiene un efecto tardío, como en la inyección de agua, la capacidad de comprensión de la RNA del fenómeno en estudio se ve disminuida significativamente, al punto en que no se encuentra la relación que se espera.

5.3.3. SIRMANN TIPO III

La estructura SIRMANN III se propone para interpolar propiedades tales como la permeabilidad y la porosidad, que dependen principalmente del origen de la estructura geológica del yacimiento, más que del tiempo.

Para evaluar el SIRMANN tipo III, se utilizarán datos del campo Manguitos y se hará una comparación con una interpolación de tipo Kriging, por ser una de las más favorables para las interpolaciones de datos de tipo geológico (ver figura 88). Las entradas de la RNA utilizadas son de tipo coordenadas (este, oeste y profundidad) y las salidas son la porosidad y la permeabilidad.

Figura 88. Kriging para permeabilidad y porosidad, campo Manguitos.



Los resultados se comparan de dos maneras. La primera (figuras 89a, 89B, 90a y 90b), cotejando en el plano cartesiano los datos obtenidos con los esperados (cuando la respuesta es buena, los datos se acercan a una línea recta de pendiente igual a uno), y la segunda graficando, en contornos de color, los valores que arroja la RNA (figuras 50 y 51). En la parte izquierda de la comparación en cartesiano se presenta el ajuste a los datos del entrenamiento y en la derecha, el ajuste a la simulación.

En las figuras 89a y 89b se muestra que la regularización bayesiana presenta resultados desfavorables de ajuste, incluso para los datos de entrenamiento. En consecuencia los resultados de la extrapolación son igualmente malos (ver figuras 91a y 91b).

Figura 89(a). SIRMANN tipo III, TRAINBR, 3:4:2, permeabilidad en cartesiano.

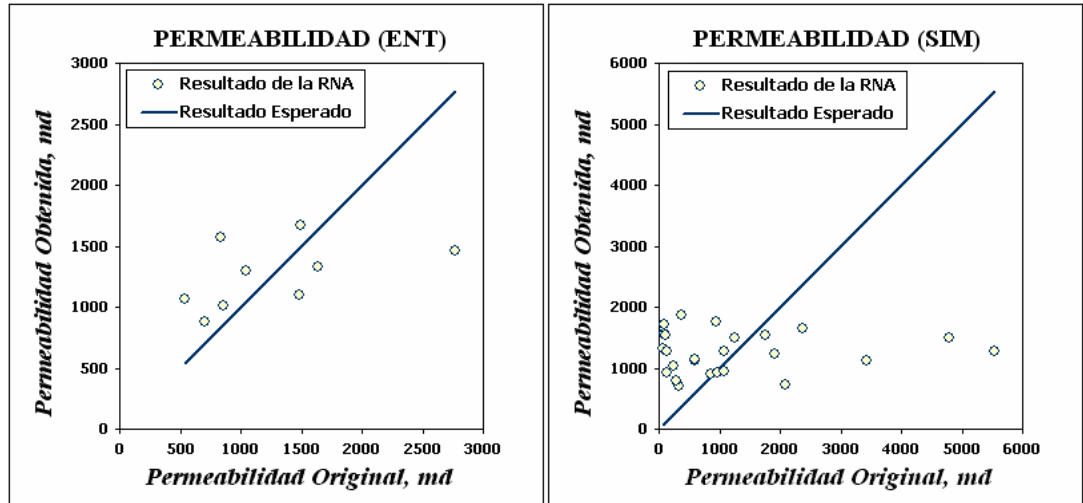
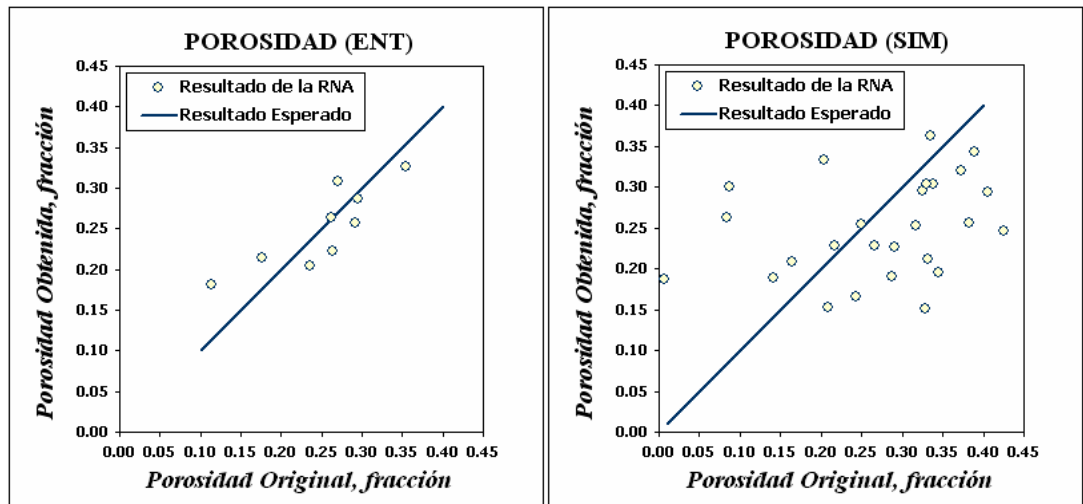


Figura 89(b). SIRMANN tipo III, TRAINBR, 3:4:2, porosidad en cartesiano.



Los resultados obtenidos con el entrenamiento Leverberg-Marquardt son aceptables, toda vez que los datos de permeabilidad/porosidad esperados se

encuentren dentro del rango de los datos de simulación. Lo mismo aplica para las coordenadas de este, norte y profundidad.

Figura 90(a). SIRMANN tipo III, TRAINLM, 3:4:5:2, permeabilidad en cartesiano.

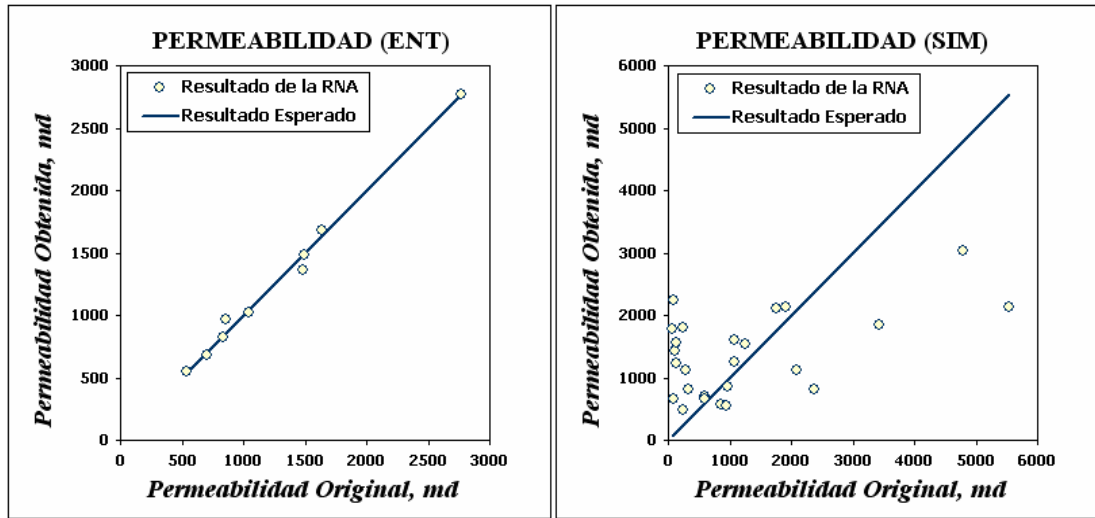
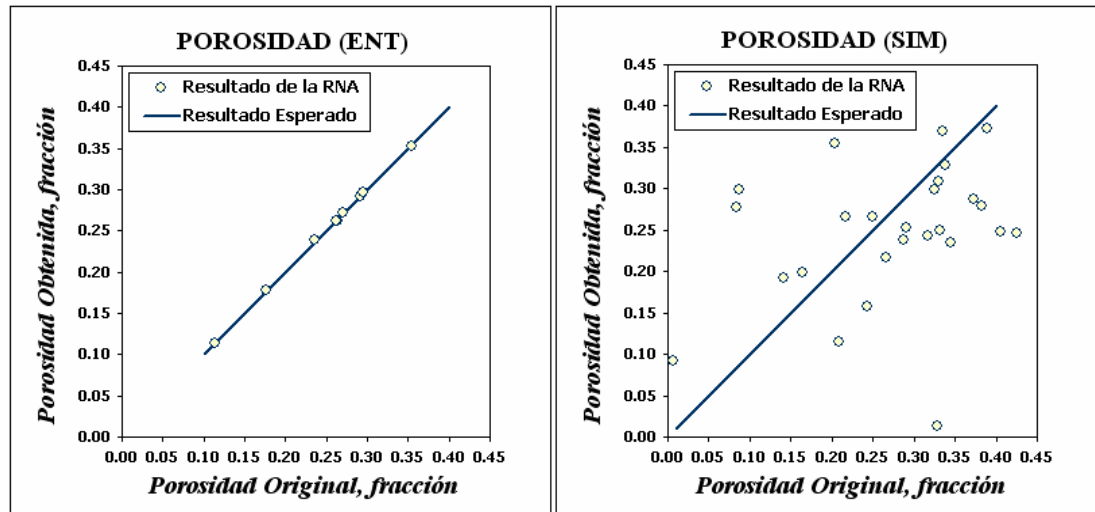


Figura 90(b). SIRMANN tipo III, TRAINLM, 3:4:5:2, porosidad en cartesiano.



Aunque el grado de ajuste del TRAINLM no es el mejor, sí se obtiene una respuesta de RNA aceptable para el caso de la extrapolación a todo el campo (ver figuras 92a y 92b). En este punto hay que tener presente que el valor de la

interpolación de tipo kriging, no es necesariamente el valor real que se tiene en el subsuelo.

Figura 91(a). SIRMANN tipo III, TRAINBR, 3:4:2, permeabilidad en contornos.




Figura 91(b). SIRMANN tipo III, TRAINBR, 3:4:2, porosidad en contornos.




Figura 92(a). SIRMANN tipo III, TRAINLM, 3:4:5:2, permeabilidad en contornos.





Figura 92(b). SIRMANN tipo III, TRAINBR, 3:4:2, porosidad en contornos.



Es apreciable que mientras el entrenamiento TRAINBR sólo dibuja sectores horizontales, el entrenamiento TRAINLM muestra curvaturas que pueden parecer más consistentes con un fenómeno de deposición sedimentaria para un yacimiento.

5.3.4. SIRMANN TIPO IV


Algunos de los fenómenos de interés en un campo petrolífero, dependen de variables tanto estáticas como dinámicas. Por tal razón se propuso el esquema SIRMANN tipo IV y para ilustrar su comportamiento, se presenta un ejemplo de construcción de mapas de potencial productivo para el campo Yatí.

Inicialmente se hace el entrenamiento y simulación de la RNA, utilizando como variables de entrada:

- El tiempo.
- La producción acumulada del campo.
- La presión de fondo fluyente.
- Las coordenadas este y norte.

Y como variable de salida los caudales de aceite. Los resultados esperados deben ser similares a los que se presentan en la figura 93.

Figura 93. Potencial esperado en el campo Yatí por Kriging.



Los resultados de las simulaciones con RNA fueron desfavorables. Aun cuando se modificaron las épocas de entrenamiento y el número de fechas seleccionadas, sólo un par de casos mostraron un comportamiento medianamente cercano al esperado (ver figura 94).

Figura 94. Potencial de producción en Kriging y según entrenamiento Levenberg-Marquardt, estructura 5:4:1 (campo Yatí).

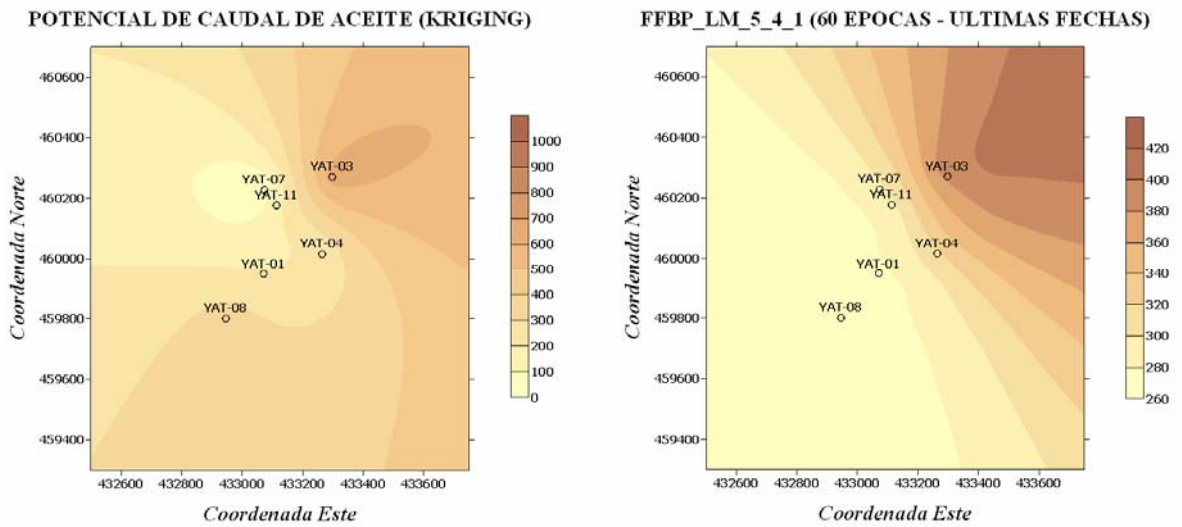
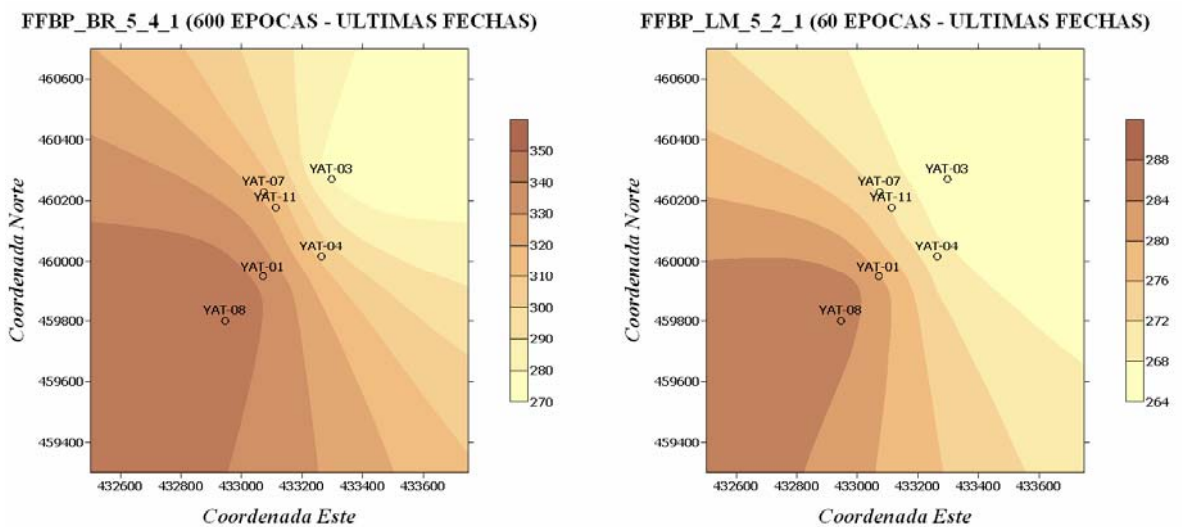


Figura 95. Potencial de producción en BR 5:4:5:1 y LM 5:2:1 (campo Yatí).



Los demás entrenamientos para éste modelo de entradas y salidas en SIRMANN tipo IV muestran respuestas inconsistentes. Incluso algunos mapas de potencial se muestran totalmente opuestos al perfil esperado (ver figura 95).

Figura 96(a). Potencial de producción en LM 3:2:1 y LM 3:2:2:1 (campo Yatí).

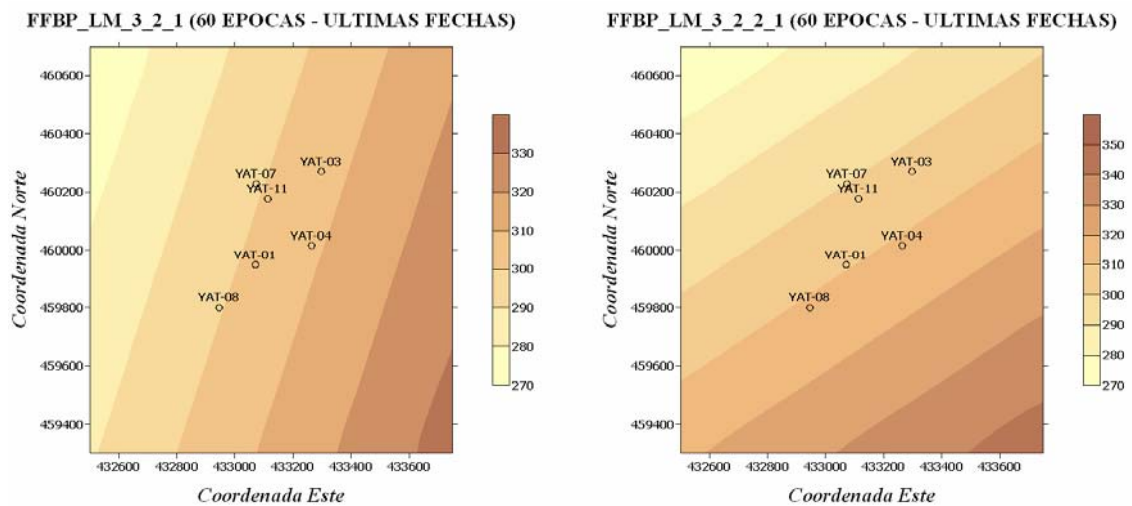
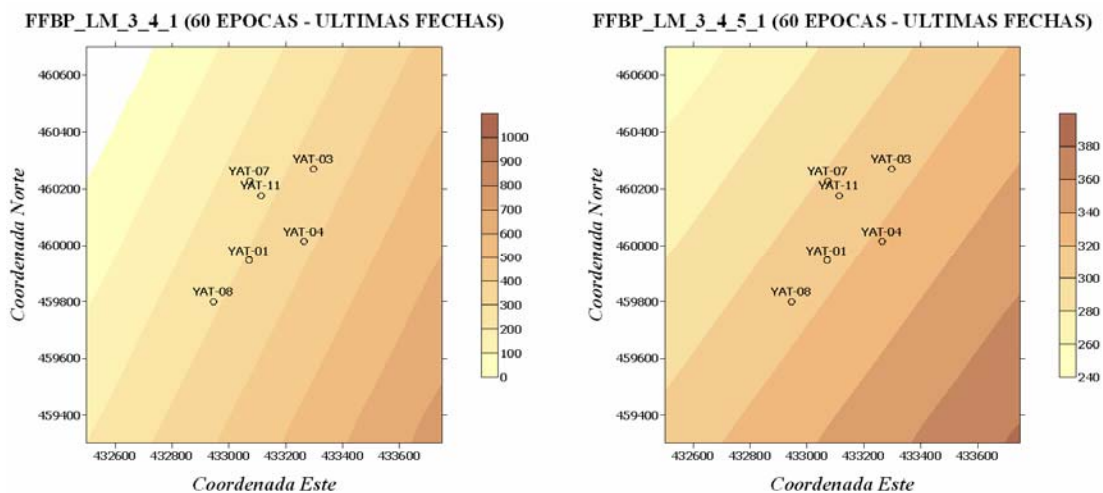


Figura 96(b). Potencial de producción en LM 3:4:1 y LM 3:4:5:1 (campo Yatí).



Para mejorar el entrenamiento de las RNA del modelo SIRMANN tipo IV, se intentó simular el potencial de producción utilizando solamente tres variables de entrada (este, norte y tiempo) y luego dos variables (este y norte). Los resultados

para tres variables de entrada indican que la red en entrenamiento Levenberg-Marquardt puede discriminar, no con mucho detalle, zonas de diferente potencial de producción (ver figuras 96a y 96b).

Para el entrenamiento con dos variables, los resultados fueron similares que para el de tres variables (ver figuras 97a y 97b).

Figura 97(a). Potencial de producción en LM 2:2:1 y LM 2:2:2:1 (campo Yatí).


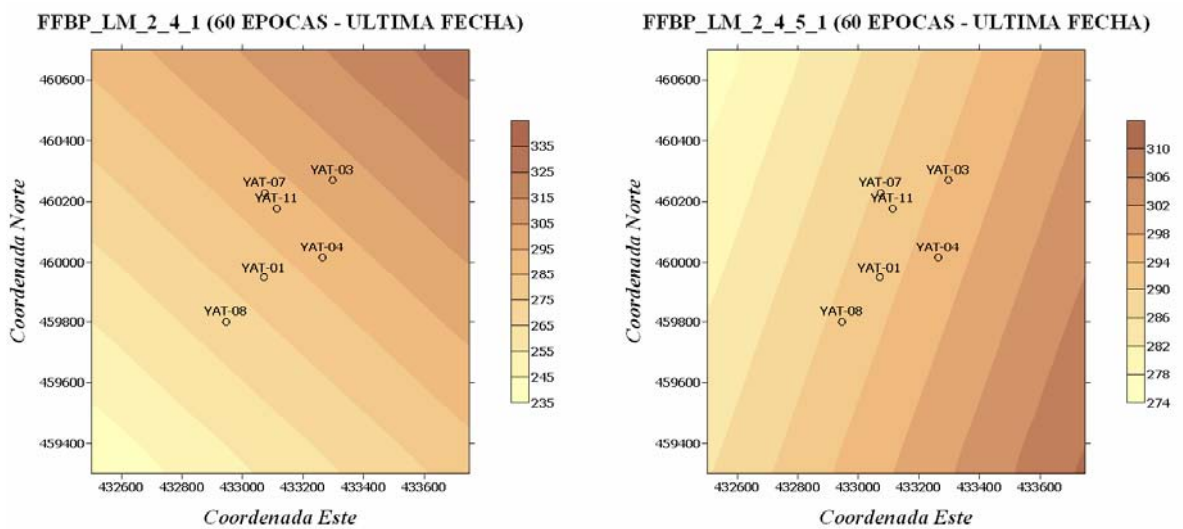



Figura 97(b). Potencial de producción en LM 2:4:1 y LM 2:4:5:1 (campo Yatí).



El resultado de la red en entrenamiento de regularización bayesiana fue un valor constante en la mayoría de los casos (ver figura 98). Este valor, aunque parezca desfavorable a simple vista, puede estar de la mano con la teoría de que el potencial de los pozos nuevos a perforar, es un promedio ponderado de los pozos del bloque de interés.

Figura 98. Potencial de producción en BR 2:2:1 y BR 2:4:1 (campo Yatí).



6. METODOLOGÍA PARA EMULAR LA PRODUCCIÓN EN UN CAMPO PETROLÍFERO CON REDES NEURONALES ARTIFICIALES

De acuerdo con los resultados obtenidos en la evaluación de los diferentes esquemas de RNA, se presenta esta metodología como un resumen de los pasos que se deben seguir para entrenar redes que capturen las relaciones que determinan el comportamiento de producción en un campo petrolífero.

El objetivo principal de éste capítulo, es compilar todas las pautas consideradas como importantes para quienes decidan emprender un estudio similar al presentado en éste documento. Por lo tanto, las ideas que se expresan a continuación, aún cuando son consecuencia directa de las pruebas que se hicieron en el desarrollo del trabajo de investigación, contienen tanto nuevos aportes como conclusiones ya conocidas y expuestas ampliamente por otros autores.

6.1. ASPECTOS GENERALES

Los siguientes puntos son sugerencias de tipo general, que son aplicables a cualquier problema que se quiera abordar con RNA:

1. Se deben seleccionar las variables más representativas del problema a simular. Aquellas que al cambiar de valor, tienen un efecto claro y directo sobre la variable de interés. No necesariamente, hay que incluir todas aquellas que están en las ecuaciones que describen el sistema de interés.
2. Los datos de entrenamiento y simulación deben ser normalizados, de manera que queden ubicados en el rango que abarcan las funciones de activación.

3. La extrapolación no debe confiarse para datos demasiado lejanos del rango de entrenamiento.
4. Se deben incluir en los datos originales, las restricciones físicas y todas las relaciones que se puedan inferir del sistema que se quiere emular.
5. Después del entrenamiento, y sin importar cuán bueno es el ajuste de la RNA a los datos originales, se debe verificar si la red cumple con los principios físicos básicos del problema en estudio y/o si los resultados son consistentes con el comportamiento esperado.
6. Para declarar un tipo de red como favorable, es importante que los resultados obtenidos con la misma puedan repetirse. Estableciendo así el grado de confiabilidad y descartando que el acierto no sea cuestión de coincidencias.

6.2. MODELAMIENTO DE UN SOLO POZO

En el modelamiento individual de pozos se encontró más favorable:

1. Utilizar como algoritmo de entrenamiento la regularización bayesiana, toda vez que se quiera extrapolar en el tiempo, datos de producción.
2. Incorporar, tanto como sea posible y necesario, las variables del modelo de flujo a estado pseudo-estable.
3. Incluir las restricciones:
 - a. Para días de producción/inyección cero, volúmenes de producción cero.
 - b. A igual presión de fondo y de yacimiento, producción cero.
 - c. A diferentes presiones de fondo, se cumple la ecuación de Vogel, manteniendo constantes las relaciones volumétricas entre las fases.
4. No procurar simular el efecto de las fases agua y gas sobre el crudo, a menos que se incluyan, como restricciones, las relaciones de permeabilidades relativas.

6.3. MODELAMIENTO DE VARIOS POZOS

En el modelamiento colectivo de pozos se encontró más favorable:

1. Preferir el entrenamiento con el algoritmo de Levenverg-Marquardt.
2. Utilizar sólo las variables que afectan directa y significativamente el parámetro de interés. Es decir, no esperar que la red descubra entre variables, relaciones extremadamente sutiles o desfasadas en el tiempo.
3. Reducir el número de variables y datos de entrenamiento, tanto como sea posible. Si una entrada no afecta significativamente al sistema, debe ser eliminada para favorecer la respuesta de la red.
4. En la extrapolación de variables estáticas, es mejor tener mayor número de datos abarcando el mayor rango de valores posibles.
5. En la combinación de variables estáticas y dinámicas, hay que tener especial cuidado con la respuesta de la red, dado que las pruebas indican multiplicidad e incluso contradicción en las respuestas de la red.

7. CONCLUSIONES Y RECOMENDACIONES

En éste trabajo investigativo se planteó un interrogante acerca de la posibilidad de simular el comportamiento de producción de un campo petrolífero utilizando redes neuronales artificiales.

Para validar la hipótesis inicial se esbozaron múltiples modelos de red, desde los más simples hasta los más generales, partiendo desde el caso particular de un solo pozo hasta llegar al caso más general de todo el campo.

Se procuró el estudio de todos los posibles modelos, teniendo en cuenta las diferentes variables que influyen en las relaciones de flujo y entendiendo que cada parámetro puede ser dinámico o estático de acuerdo con el escenario.

Los datos, utilizados para el entrenamiento y comparación, fueron tomados de información real de campos colombianos y de la simulación numérica de un campo ficticio.

Una aplicación en Delphi Borland fue construida inicialmente para comprender al detalle el funcionamiento de las redes **feedforward** en entrenamiento **backpropagation**. Sin embargo, el software final que se utilizó a modo de laboratorio para construir y probar cada modelo fue escrito en lenguaje Matlab.

Los resultados indican que las redes neuronales artificiales de tipo **backpropagation** en entrenamiento Levenberg-Marquardt y regularización bayesiana, son útiles para emular el comportamiento de producción de un pozo petrolífero, porque copiaron de forma apropiada, tanto los datos reales, como los datos provenientes de la simulación numérica. Ésta situación debe ser ventajosa para el análisis individual de pozos en aquellos campos en los que se cuenta con

tecnologías de medidores, que registran datos de producción en tiempo real y que por lo tanto, requieren del procesamiento y modelamiento de grandes volúmenes de información.

La respuesta de las RNA tuvo una estrecha relación con el pre-procesamiento que se hizo a los datos de entrenamiento. Las redes funcionaron mejor cuando los datos contenían poco ruido y cuando la escala de los mismos se llevó al rango de las funciones de activación. Adicionalmente, fue muy favorable incluir en los datos de entrenamiento, un conjunto de relaciones propias del modelo a simular. De éste modo, se le restringió a la red el conjunto de posibles soluciones debido a la mayor cantidad de información incorporada en las entradas; por esta razón su respuesta estuvo, por fuerza, más acorde con la realidad del fenómeno simulado.

Las variables seleccionadas que mejores resultados mostraron fueron aquellas que tenían un impacto directo sobre el parámetro de interés. Las causalidades poco claras y desfasadas en el tiempo, no llegaron a ser descritas apropiadamente por la red. Por ejemplo, en el caso de los pozos inyectoros que ejercían influencia sobre los productores, la RNA no encontró la relación entre los dos pozos del análisis. Esta situación se explica porque la inyección tarda muchos meses en afectar la producción y el cambio en el caudal del productor es muy sutil.

Con respecto a la simulación colectiva de pozos, y contrario a lo que una solución intuitiva sugeriría, fue más favorable utilizar la menor cantidad de variables, así la red llegó a obtener el mejor provecho del entrenamiento sin llegar a “confundirse”, encontrando relaciones que en la realidad podrían no existir.

Cuando se utilizaron las redes para encontrar interacciones entre pozos, las respuestas no fueron favorables porque la información que se pretendía encontrar era la misma que se requería para que la red fuera entrenada de forma apropiada (delimitación dimensional y de rango).

Las interpolaciones y extrapolaciones en el espacio (calculando datos para diferentes coordenadas), hechas con las redes neuronales, mostraron que la tendencia de respuesta de la red es hacia un promedio ponderado. Estos resultados son consistentes con la realidad de algunos campos colombianos y con anteriores trabajos que procuraban establecer zonas de interés para la perforación de nuevos pozos. Sin embargo, se tiene nuevamente el caso de una solución sofisticada para un problema que parece no necesitar mayor esfuerzo computacional.

Finalmente, después del uso de las redes neuronales artificiales para la simulación del comportamiento de producción, se concluye que las RNA solucionan los problemas más sencillos, precisamente aquellos que ya pueden ser resueltos con otras herramientas más simples. Mientras que en los casos más complejos no se encuentra una solución satisfactoria, porque la respuesta que se quiere encontrar con la red es parte de los requerimientos de entrenamiento que garantizan que los resultados se ajusten al sistema físico que se quiere simular.

REFERENCIAS

1. ANIL, K. Jain; MAO, Jianchang and MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. IEEE. March, 1996.
2. ARPS, J. J. Estimation of primary oil reserves. Trans. AIME, 207, 1956.
3. BEGGS, H. D. Production Optimization Using NODAL analysis. OGCI 1999.
4. BOOMER, Robert J. Predicting production using a neural network (artificial intelligence beats human intelligence). En: Society of Petroleum Engineers (June 1995). SPE 30202.
5. CENTILMEN, A.; ERTEKIN, T., and GRADER, A. S. Applications of neural networks in multiwell field development. En: Society of Petroleum Engineers (October 1999). SPE 56433.
6. CUN, Y. L. Une procedure d'apprentissage pour reseau a seuil assymetrique. Proceedings of Cognitiva, 85 (1985). Citado por: ver referencia 14.
7. CRAFT B. C. and HAWKINS M. F. Applied Petroleum Reservoir Engineering. 1991. Prentice Hall.
8. DEMUTH, Howard and BEALE Mark. Neural Networks Toolbox. User's Guide. Version 4.
9. GENTRY, R. W. Decline Curve Analysis. En: Journal of Petroleum Technology (Enero, 1972). SPE 3356.
10. GOLAN, M. and WHITSON, C. H. Well Performance. 2 ed. Prentice Hall, Englewoods Cliffs, NJ, 1991.
11. HAYKIN, S. Neural Networks. A Comprehensive Foundation. 2 ed. Prentice Hall, 1999.
12. JIKICH, S. A. and POPA, A. S. Hyperbolic Decline Parameter Identification Using Optimization Procedures. En: Society of Petroleum Engineers (2000). SPE 65634.
13. KEENAN, Jhon. Statistical Techniques for Data Analysis. Lewis Publishers, Inc.

14. KRÖSE, Ben and van der SMAGT, Patrick. An Introduction to Neural Networks. 6 ed. Amsterdam: University of Amsterdam, 1996.
15. LIN, Ch and ROWLAND D. A. Determining the constants of hyperbolic production decline by a linear graphic method. En: Society of Petroleum Engineers (1982). SPE 11329.
16. MACKAY, David. Bayesian Methods for Adaptive Models. PhD. Thesis. California Institute of Technology, 1992.
17. MCCULLOCH, W. S., and PITTS, W. A logical calculus of the ideas immanent in nervous activity. En: Bulletin of Mathematical Biophysics. Vol. 5. p. 115-133. Citado por: ver referencia 14.
18. MINSKY, M., and PAPERT, S. Perceptrons: an introduction to computational geometry. The MIT Press, 1969. Citado por: ver referencia 14.
19. NAKAMURA, Shoichiro. Análisis numérico y visualización gráfica con Matlab. Prentice Hall, 1997.
20. PANDA, M. N., and CHOPRA, A. K. An integrated approach to estimate well interactions. En: Society of Petroleum Engineers (February 1998). SPE 39563.
21. PARKER, D. B. Learning-Logic (Tech. Rep. Nos. TR-47). Cambridge, MA: Massachusetts Institute of Technology, Center for Computational Research in Economics and Management Science, 1985. Citado por: ver referencia 14.
22. RUMELHART, D. E.; HINTON, G. E. and WILLIAMS R. J. Learning representations by backpropagating errors. Nature, 323, p. 533-536. Citado por: ver referencia 14.
23. RUZ, S. y CALDERÓN, Z. Estimación de reservas y cálculo de los parámetros de declinación hiperbólica. Una comparación entre redes neuronales y métodos numéricos. En: Congreso Colombiano del Petróleo (11º : 2005: Bogotá).
24. RUZ, S. and MENDOZA, A. Stimulation Jobs Evaluation Based on Decline Curve Analysis. En: Revista CT&F – Ciencia, Tecnología y Futuro, 2006. Vol. 3. Num. 2.

25. SHAHAB M. Surrogate Intelligent Models (SIMs). Disponible en internet en: <http://shahab.pe.wvu.edu/research/SIM/SRM.html>
26. SNEDECOR, G. W. and COCHRAN, W. G. Statistical methods. 6 ed. Ames. IA: Iowa University Press, 1967. Sect. 7.8. Citado en: KEENAN, Jhon. Statistical Techniques for Data Analysis. Lewis Publishers, Inc.
27. The Mathworks Inc. Curve Fitting Toolbox. User's Guide. Version 1. 2001-2002.
28. WERBOS, P. J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Unpublished doctoral dissertation, Harvard University, 1974. Citado por: ver referencia 14.
29. WIGGINS, M. L. and STARTZMAN, R. A. An Approach to Reservoir Management. SPE 20747.
30. WYCOFF, R. D.; BOTSET, H. G.; MUSKAT, M. and MERES, M. W. Flow of gas-liquid mixtures through sand. Transactions of AIME, 1937. Vol. 123. p. 69-96. Citado en: ver referencia 10.