

Estimación de Parámetros de Pozos Petroleros Utilizando Inteligencia Artificial

Edgar Camargo*, José Aguilar**, Addison Ríos**, Francklin Rivas***, Joseph Aguilar-Martin[^]

*Doctorado en Ciencias Aplicadas, Facultad de Ingeniería, Universidad de los Andes, Mérida, Venezuela (e-mail: edgarc@ula.ve)

**CEMISID, Facultad de Ingeniería, Universidad de los Andes, Mérida, Venezuela (e-mail: aguilar@ula.ve, ilich@ula.ve).

*** Laboratorio de Sistemas Inteligentes. Universidad de los Andes, Mérida, Venezuela (e-mail: rivas@ula.ve).

[^] Grup SAC, Universitat Politècnica de Catalunya, Campus de Terrassa, España (e-mail:aguilar@laas.fr).

Resumen: En este trabajo se presenta la Estimación de Parámetros de Fondo de Pozos Petroleros. La Estimación se realiza a partir de técnicas de Computación Inteligente (redes neuronales y lógica difusa). Para validar los resultados, la estimación se aplica en pozos que requieren levantamiento artificial usando datos del cabezal (presiones de gas y producción).

Palabras claves: modelos neuro-difusos, sistema de producción petrolero, pozos por levantamiento artificial por gas, estimación de parámetros.

1.- INTRODUCCION

En la actualidad el control de los yacimientos de hidrocarburos está a la par con la tecnología. La posibilidad de instalar dispositivos para la medición de variables de fondo y superficie permiten la supervisión y control del pozo a nivel del cabezal, identificar el aporte real del yacimiento a través del flujo de producción que proviene de zonas específicas, el desplazamiento del flujo de producción al pozo y su estado operacional de producción [Going, et al., 2006].

Ahora bien, la gran mayoría de completaciones (tubería de pozo mas arreglo mecánico) tradicionales están ausentes de equipos de supervisión de fondo, dando como resultado una cantidad limitada de datos del yacimiento, debido a que el uso de dicha tecnología es altamente costoso, como también su instalación requeriría la paralización de los pozos activos, más los costo de mantenimiento y poca vida útil (menor a 5 años); estas son algunas de las razones por la cual una gran cantidad de pozos no cuentan con tecnología de medición de fondo.

Por esta razón, en este trabajo se propone estimar la Presión de Fondo ($P_{f_{INF}}$) utilizando técnicas de Inteligencia Artificial, ya que han demostrado ser efectivas en procesos de automatización industrial, donde el manejo del conocimiento o la toma de decisiones juegan un factor importante [T. Yamakawa, 1992, Eikrem, et al., 2002, Takeshi, 2004].

Finalmente, la validación de la estimación de la variable de fondo se realizará a través de un índice, el cual consiste en calcular la diferencia entre la Presión de la Tubería de Producción Medida (THP_M) y la Presión de la Tubería de Producción Inferida (THP_{INF}); si el resultado es menor a un factor β indica que el valor de estimación de fondo es correcto, razón por la cual se propone estimar esta segunda variable (THP_{INF}), ya que las estructuras de estimación son similares, y por otra parte, se dispone de la tecnología de medición del THP a nivel de cabezal del pozo (por su costo de implantación y cero impacto operacional en su instalación y mantenimiento).

La Estimación de las presiones de tubería de producción y de fondo de pozo se realizan en pozos petroleros que producen por levantamiento artificial por gas (“Consiste en inyectar gas a una presión determinada en la parte inferior de la columna de fluido de la tubería del pozo, a diferentes profundidades, con el fin de disminuir el peso de la misma, y de esta forma ayudar a subir los fluidos del yacimiento desde el fondo del pozo hasta la superficie”). Se realiza en este tipo de método debido a la importancia del gas de levantamiento en la industria petrolera Venezolana.

2.- INTELIGENCIA ARTIFICIAL

2.1 Modelos Neuro- Difusos

Las redes neuronales artificiales consisten en un sistema que trata de emular el comportamiento de las redes neuronales biológicas en lo relativo al aprendizaje y la capacidad de generalización. Por otro lado, la lógica difusa ha extendido la lógica tradicional, para proveer la

capacidad de manejo de información imprecisa. Con la finalidad de aprovechar las bondades de las redes neuronales artificiales y los modelos lógico - difusos, surgió una nueva estructura llamada modelos neuro-difusos, la cual ha demostrado dar buenos resultados en la captura del comportamiento de sistemas complejos [T. Yamakawa, 1992, Yamakawa, 1994, Jansen et al., 1999, Salcedo et al., 2006].

Los modelos neuro-difusos tienen como elemento principal a las neuronas difusas. La estructura de la neurona difusa se muestra en la (Fig. 1). En ésta, los pesos sinápticos no son constantes sino funciones no lineales de las entradas, representadas por modelos lógico- difusos basados en una colección de reglas de la forma Si - Entonces que usan un razonamiento aproximado en el proceso de inferencia. Esta estructura no posee una función de activación, sino un punto de suma que genera la salida al agregar las salidas de los modelos lógico - difusos para cada entrada [Yamakawa, 1994].




Fig. 1. Neurona Difusa

El espacio de cada una de las variables de entrada es dividido en varios segmentos que conformarán los subconjuntos difusos de cada variable, a los cuales son asignados valores lingüísticos. Cada uno de los segmentos es caracterizado por una función de membresía.

El conjunto de reglas, que conforman la base de conocimiento de cada modelo lógico – difuso es representado en forma general por:

Si la señal de entrada x_i está incluida en el segmento difuso k , entonces el peso sináptico de salida es w_{ik} .

En estas reglas el consecuente es un valor constante w_{ik} con función de membresía igual a uno (1) para el valor w_{ik} y cero (0) para cualquier otro valor.

La sinapsis de salida de cada modelo lógico – difuso es obtenida mediante un mecanismo de inferencia con difusificación y desdifusificación [Yamakawa, 1994], y está dada en forma general como se muestra en la (Fig. 2).




Fig.2. Sinapsis de la ND

El proceso de entrenamiento consiste en la presentación de cada uno de los patrones y ajustar los pesos de las sinapsis, denotados por w_{ik} . Cada valor puntual de una señal de entrada activa solo dos reglas, tal como se observará mas adelante, lo cual indica que al aplicar el proceso de inferencia en cada modelo difuso, los pesos constantes de cada sinapsis que influyen en la salida son uno o dos, y estos son los que se deben modificar para lograr la salida deseada. El ajuste de estos pesos se hace cada vez que se presenta un patrón de entrenamiento según la ecuación (1). Cada vez que se presentan todos los patrones de entrenamiento se dice que se ha concluido un ciclo de entrenamiento. Durante el entrenamiento de una neurona difusa se deben ejecutar varios ciclos de entrenamiento, hasta lograr un buen ajuste del modelo.

De esta manera, el aprendizaje para una neurona difusa consiste en modificar uno o dos pesos de cada sinapsis, correspondiente a las reglas activadas ante una entrada específica, hasta lograr la salida deseada.

$$w_{ik}(T+1) = w_{ik}(T) + \Delta w_{ik}(T) \quad (1)$$

$$\Delta w_{ik} = -\alpha \frac{\partial E_j}{\partial w_{ik}} = -\alpha \frac{\partial E_j}{\partial y_j} \frac{\partial y_j}{\partial f_i(x_j)} \frac{\partial f_i(x_j)}{\partial w_{ik}} = -\alpha (y_j - y_d) \mu_k(x_j) \quad (2)$$

La salida de la neurona difusa, y , viene dada por la siguiente ecuación:

$$y = f_1(x_1) + f_2(x_2) + \dots + f_m(x_m) = \sum_{i=1}^m f_i(x_i) \quad (3)$$

3.- FUNDAMENTOS TEÓRICOS DE POZOS POR LEVANTAMIENTO ARTIFICIAL POR GAS

Consiste en inyectar gas a una presión determinada en la parte inferior de la columna de fluido de la tubería del pozo, a diferentes profundidades, con el fin de disminuir el peso de la misma, y de esta forma ayudar a subir los fluidos del yacimiento desde el fondo del pozo hasta la superficie. Así, en los pozos explotados por el método de LAG de flujo continuo, el gas es inyectado continuamente al pozo a fin de que se mezcle con los fluidos del mismo y se reduzca la densidad de la columna de fluidos, disminuyéndose la

diferencia de presiones entre el fondo del pozo y la superficie.

La curva de producción de un pozo que produce a través del método de inyección de gas (ver Fig. 3), indica que a medida que la tasa de inyección de gas aumenta, la producción también aumenta hasta alcanzar su máximo valor (Región Estable); tal que incrementos adicionales en la inyección o por debajo de la inyección necesaria causarían una disminución en la producción (Región Inestable) [Hernández, et al., 2001, Eikrem, et al., 2002].

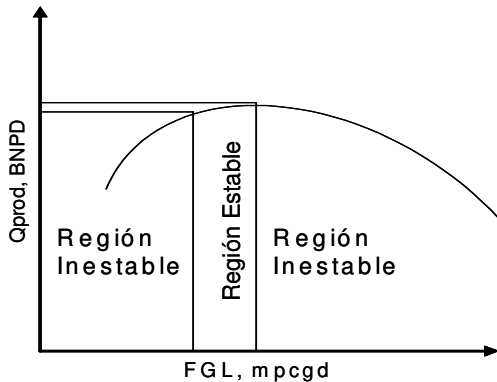


Fig. 3. Modelo de comportamiento de un pozo produciendo con método de inyección de gas.

En tal sentido, para la implantación en campo de este método LAG se requiere de un arreglo de instrumentación y control, para obtener la tasa de producción estimada por el modelo del pozo [Camargo et al., 2007], Para tal fin se requiere la medición y control de las siguientes variables (ver Fig. 4): Flujo de Gas de Levantamiento (FGL, expresado “mpcgd” miles pie cúbico gas día), Tasa de Producción (Qprod, expresado “BNPD” barriles neto producción diaria), Presión del Gas Inyectado (GLP), Presión Diferencial del Gas Inyectado (GLDP), Presión del Revestidor (CHP), Presión Tubería de Producción (THP). La medición del flujo inyectado de gas se realiza usando las variables GLP y la caída de presión GLDP. La medición de la presión del revestidor (CHP) permite conocer la presión que ejerce el gas en el revestidor del pozo, de igual manera la presión ejercida por el crudo en la tubería (THP) y en la línea de producción (PLP). Además, existen otras variables que podrían considerarse para enriquecer más la caracterización del proceso, como las temperaturas y los grados API que existen en el proceso y la medición de la presión (Pf) y temperatura (Tf) de fondo permiten identificar las condiciones de la zona de producción.

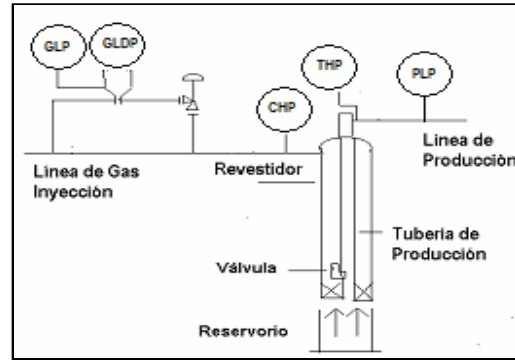


Fig. 4. Diseño Esquemático de un Pozo con Método de Extracción de Crudo Gas.

4.- ARQUITECTURA DEL MODELO NEURO DIFUSO

Los objetivos del método LAG son reducir la densidad de la columna de fluido con la tasa de inyección de gas, la cual medimos y calculamos a través de las variables (GLP y GLDP), y disminuir la presión desde el fondo hasta la superficie generada por (Pf, THP). Razón por la cual se propone estimar las presiones de fondo y tubería con las presiones de gas y producción, lo que es viable por la relación física que existe entre las mismas.

En la (Fig. 5) se presenta la arquitectura Neuro difusa, con las siguientes funciones: la Identificada como ND₁ permitirá estimar el THP con las variables de superficie, presión gas inyectado (GLP), presión diferencial del gas inyectado (GLDP) y presión del revestidor (CHP). La identificada como ND₂ estimará la presión de fondo, la cual tendrá como entrada las variables de salida de ND₁, más la variable THP medida. Finalmente, para validar el valor de inferencia de la presión de fondo (Pf_{INF}), se propone un índice, que consiste en calcular la diferencia entre ITHP_M - THP_{INF}; si es menor a β, indica que el valor es correcto, si no se deben registrar nuevos valores de fondo, debido a la presencia de un escenario operacional de fondo diferente al que fue usado para entrenar el sistema neurodifuso. Posteriormente se debe realizar de nuevo la estimación de dicha presión con ND₂.

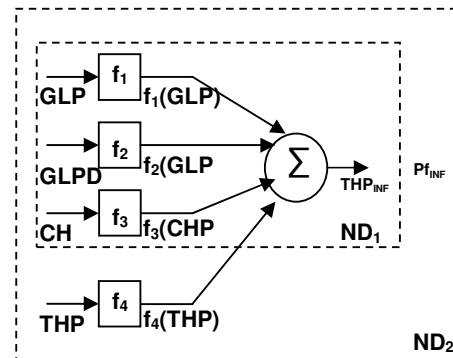


Fig. 5. Esquema Neuro Difuso para la Estimación Presión de Superficie (ND1) y Presión de Fondo (ND2)

5.- RESULTADOS DE LA APLICACIÓN DEL SISTEMA NEURO DIFUSO

5.1 Caso de Estudio para Pozo por Levantamiento Artificial por Gas

En las Tablas 1 y 2, se presenta el Sistema de Completación mecánica desde el fondo hasta la superficie y las Propiedades Física del Fluido del Pozo donde se realizará el estudio de estimación de parámetros de fondo y superficie.

Tabla 1. Propiedades Físicas del Fluido

PVT	
Gravedad Crudo (API)	25°
Corte de Agua (%)	6,02
Profundidad Perforación (ft)	3500

El Flujo se desplaza sin reductor hacia la Estación de Flujo, ubicada a 5360,89 ft, y recibe gas del Múltiple de Gas, ubicado a 508,530 ft del mismo. Las características generales de flujo no han sido modificadas durante la prueba, no se cambió el reductor, no se cambió la zona productora, ni se realizó alguna estimulación química u otra alteración sobre la productividad del pozo. La completación del pozo productor vertical de 3489 ft de profundidad, esta compuesta por dos válvulas de inyección de diámetro interno de 2,43 in, tal como lo describe la Tabla 2.

Tabla 2. Completación Mecánica del Pozo

Pozo	Profundida (ft)	Temp (F)	DI (in)
Tubería	3500,00	60.00	2,43
Válvula GL	3184,00	60.00	0
Cabezal	0	60.000	0

El pozo presenta niveles de producción en el orden de (250 ± 5) BPND, con una inyección de gas $(0,5 \pm 0,1)$ MMSCFD. Dichos valores se obtuvieron a nivel de la estación de flujo correspondiente al pozo al evaluar la estimación de parámetros (ver Fig. 6).

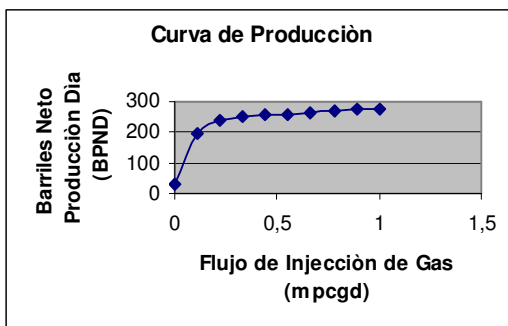


Fig. 6. Curva de Producción

En las (Fig. 7 y Fig. 8) se presentan los registros de las variables de fondo y superficie, los cuales conformarán el patrón a ser usado en el entrenamiento de las neuronas difusas. En la Figura 7 se presenta el perfil de presión de tubería de producción (THP), obtenido con el sistema de instrumentación inteligente implantado en campo [Camargo et al., 2007], donde se observa el comportamiento del THP, presentando un comportamiento estable, con oscilaciones menores al 5% con respecto al valor de referencia (175 psi) obtenido a través del Modelo de Producción del Pozo [Camargo et al., 2008].

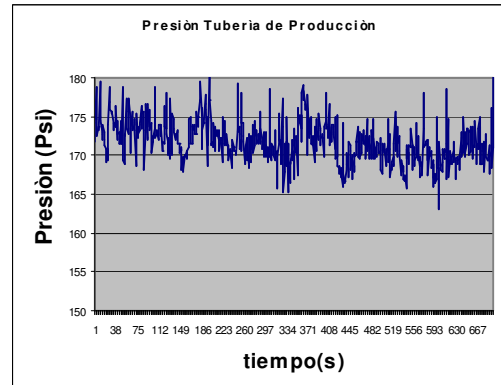


Fig. 7. Perfil Presión Tubería de Producción

Por otro lado, a nivel de cabezal de pozo se instaló un sistema portátil denominada "FGS" (Dispositivo de Fibra Óptica que registra valores de Presión y Temperatura a Nivel de Fondo de Pozo), el cual consta de una fibra óptica, una fuente láser, un analizador, y transmisores de temperatura y presión en el cabezal del pozo. La fuente láser envía pulsos de luz por un acoplador direccional óptico a lo largo de la fibra. Cada pulso de láser es dispersado por la variación de presión y temperatura en el fondo del pozo. Una parte de esta luz es dirigida hacia el analizador a través de un acoplador direccional, donde el haz presenta un decaimiento de intensidad exponencial directamente proporcional a la variación de presión y temperatura en el fondo del pozo. En la Figura 8 se presenta el perfil presión de fondo al pozo de estudio a una profundidad de 3500 ft. Es importante indicar que este sistema "FGS" solo se utilizó para tomar registro temporales de la presión de fondo.

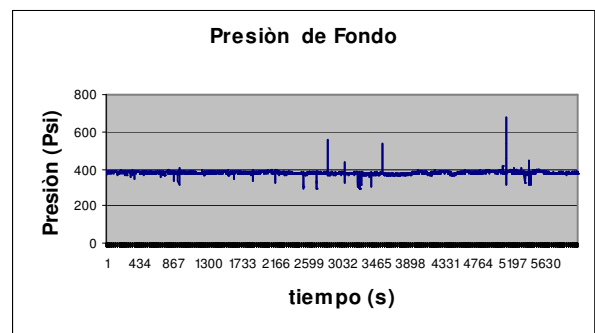


Fig. 8. Perfil Presión Fondo de Pozo

5.2 Proceso de Entrenamiento Inicial para NDI

El primer paso realizado fue el muestreo de las variables de entrada y de salida en un mismo instante de tiempo, por lo cual cada grupo de muestras conforman el patrón a ser usado en el entrenamiento de las neuronas difusas. Posteriormente se estandarizaron cada uno de los datos de entradas y de salida (min, máx), para realizar la partición difusa. De igual manera se definió el número de conjunto difusos, asociadas a funciones de membresía triangulares. Se modificaron los pesos hasta lograr la salida deseada, variando también las particiones difusas. Finalmente, el modelo fue validado con valores no usados durante el proceso de entrenamiento, (un 30% de los patrones totales).

Considérese el sistema de tres entradas y una salida, el cual es propuesto para la estimación de la presión de tubería de producción; Se tienen tres patrones de entrenamiento, donde las variables de entradas son identificadas como GLP, GLDP y CHP, y la salida THP, presentada en la Tabla 3.

Tabla 3. Patrones de Entrenamientos

Patrón	GLP	GLDP	CHP	THP
1	1705,88	9,57	1619,50	171,71
2	1723,91	11,33	1624,37	174,12
3	1720,50	10,49	1627,59	178,82

Tomando tres valores difusos para las variables de entrada y, al inicializar los pesos con valores aleatorios, la neurona difusa tiene la estructura mostrada en la (Fig. 9).

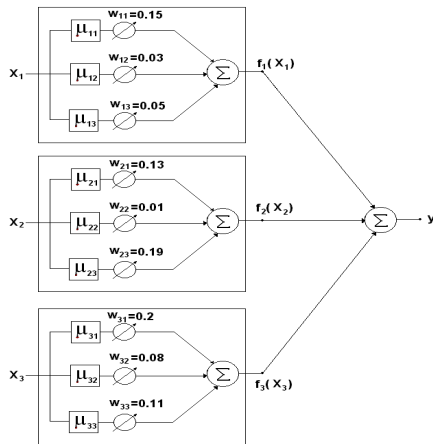


Fig. 9. Esquema Neuro Difuso con valores aleatorio

El calculo de los grados de membresía del valor de GLP =1705,88806 en cada conjunto difuso de esta variable GLP, denotados por μ_{11} , μ_{12} y μ_{13} , se hace como se muestra en la figura 10. Estos grados de membresía tienen los siguientes valores: $\mu_{11} = 0.608$, $\mu_{12} = 0.392$, $\mu_{13} = 0$.




Fig. 10. Particiones Difusa GLDP

Al calcular los grados de membresía de los valores GLDP = 9,57197762 y CHP = 1619,50378 en los respectivos conjuntos difusos, se obtienen los siguientes resultados: $\mu_{21} = 0.2145$, $\mu_{22} = 0.785$, $\mu_{23} = 0$; $\mu_{31} = 0,5$, $\mu_{32} = 0,5$ y $\mu_{33} = 0$.

Una vez obtenidos los valores de los grados de membresía, las sinapsis para las entradas están dadas por:

$$f_1(GLP) = 0.15 * 0.608 + 0.03 * 0.392 + 0.05 * 0 = 0.10296$$

$$f_2(GLDP) = 0.13 * 0.214 + 0.01 * 0.785 + 0.19 * 0 = 0.0356$$

$$f_3(CHP) = 0.2 * 0.5 + 0.08 * 0.6 + 0.5 * 0.11 * 0 = 0.14$$

De esta manera, la salida de la ND para los valores de entrada del patrón 1 esta dada por:

$$THP = 0.10296 + 0.0356 + 0.14 = 0.278$$

Al presentar el primer patrón se deben actualizar solo los pesos asociados a los conjuntos difusos en los cuales los grados de membresía son diferentes de cero. La actualización de los pesos se hace mediante la siguiente ecuación:

$$w_{ik}(T+1) = w_{ik}(T) - \alpha(y_i - y_{dj})\mu_{ik}(x_{ij})$$

De esta manera, la actualización para cada uno de los pesos al presentar el patrón 1, con $\alpha = 0.5$, es la siguiente:

$$w_{11} = 0.15 - 0.5 * (0.278 - 171,71666) * 0.608 = 52,267$$

$$w_{12} = 0.03 - 0.5 * (0.278 - 171,71666) * 0.392 = 33,631$$

$$w_{13} = 0.05 - 0.5 * (0.278 - 171,71666) * 0 = 0,05$$

$$w_{21} = 0.13 - 0.5 * (0.278 - 171,71666) * 0,2145 = 18,516$$

$$w_{22} = 0.01 - 0.5 * (0.278 - 171,71666) * 0,785 = 42,901$$

$$w_{23} = 0,19$$

$$W_{31} = 0.2 - 0.5 * (0.278 - 171,71666) * 0.5 = 43,059$$

$$W_{32} = 0.08 - 0.5 * (0.278 - 171,71666) * 0.5 = 42,939$$

$$W_{33} = 0,11 - 0.5 * (0.278-171,7166) * 0 = 0,11$$

El mismo procedimiento mostrado anteriormente para el patrón 1 debe aplicarse para los demás patrones, hasta lograr un buen ajuste. Cada vez que se actualizan los pesos, al presentar todos los patrones, se ha cumplido un ciclo de entrenamiento. El número de ciclos de entrenamiento es seleccionado por el usuario.

5.3 Resultados Obtenidos para ND1 y ND2

En la Tabla 4, y las (Figs. 11 y 12) se presentan los resultados obtenidos para la estimación de las presiones de producción y de fondo con el sistema neuro difuso.

Tabla 4. Patrones de Entrenamiento

Entradas	Salida	Patrones Entren.	Patrones Evaluar	Error Cuad.
GLP, GLDP, CHP, THP	Pf _{INF}	3250 (50%)	3250 (50%)	0,294% 0,400%
GLP, GLDP, CHP	1THP _I NF	350 (50%)	350 (50%)	0,771% 1,305%

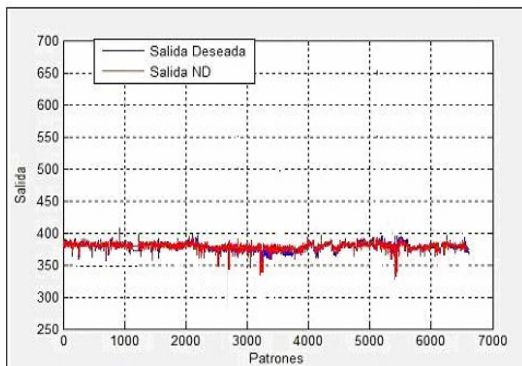


Fig. 11. Esquema Neuro Difuso para la Estimación Presión de Fondo con un 50%

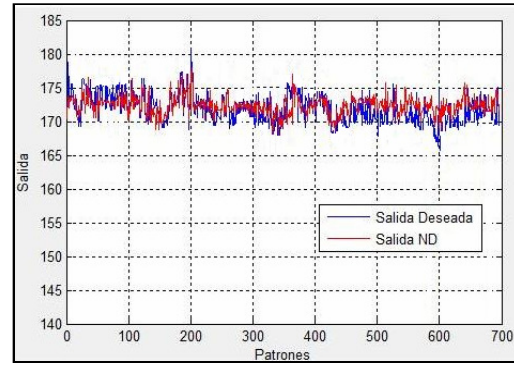


Fig. 12. Esquema Neuro Difuso para la Estimación Presión de Tubería de producción con un 50%

Los resultados obtenidos para los dos Modelos Neuro Difusos, dan una buena estimación de las variables de fondo y superficie. Los errores promedio de entrenamiento y de prueba obtenidos para la estimación de la presión de fondo fueron 0,235% y 0,331%. El error promedio de entrenamiento y de prueba obtenido para la tubería de producción fueron 0,727% y 0,872%, lo cual indican la efectividad de las redes Neuro Difusa.

El valor de β es menor a 5 psi en todo el ciclo de entrenamiento, lo cual refleja la efectividad de la estimación de superficie. Los Modelos Neuro Difuso se desarrollaron bajo el ambiente de programación MATLAB® versión 7.

6.- CONCLUSIONES

El uso de sistemas para la estimación de variables resultado ser de gran interés por el bajo costo requerido para su elaboración, por la disposición actual de sistemas de adquisición de datos y bases de datos histórica, que aportan los datos requeridos para el diseño de estos sistemas.

En el caso de la estimación de parámetros del fondo y superficie a través del Sistema Neuro difuso, resultado ser efectiva al seguir la dinámica de las presiones medidas. Su importancia está en la de disponer del valor de la presión de fondo a nivel de superficie, posibilitando la toma de decisiones sobre la producción del pozo, su estado operacional, si el fondo del pozo esta bajo la presencia de agua, sedimentos, etc.. Esto ultimo puede cambiar la tasa de producción del pozo.

La utilización de técnica de inteligencia artificial basadas en Sistemas Neuro Difusos, permitió estimar variables de fondo y superficie, con errores cuadráticos menores a un 1%, lo cual indica la efectividad de dicho sistema. En tal sentido, el uso de este sistema para otro tipo de pozo que su producción no dependa del Método LAG, se recomienda caracterizar el modelo neuro-difuso con condiciones de operación propia del pozo, y entrenarlo hasta obtener resultados confiables.

AGRADECIMIENTO

Este trabajo ha sido financiado por el FONACIT bajo el proyecto No. 2005000170, por el CDCHT-ULA a través del proyecto No. I-820-05-02-AA, y por el PCP a través del proyecto de Automatización No. 200500380, instituciones/programa a las cuales los autores expresan sus agradecimientos.

REFERENCIAS

- Camargo E, Aguilar J, Rivas F, A Ríos., (2007). Instrumentación Inteligente para mejorar la producción en Pozos por levantamiento Artificial por Gas. 8° Congreso Iberoamericano de Ingeniería Mecánica, Cusco, Perú, ISBN 978-9972-2885-3-1.
- Camargo E, Aguilar J, Rivas F, A Ríos, Aguilar Martin J., (2008). Nodal Analysis- based Design for Improving Gas Lift Wells Production. *WSEAS Transactions on Informations Science & Applications*. ISSN: 1790-0832. 706-715. Issue 5, Volume 5.
- Eikrem, G. Foss, L. Imsland, H, and Golan, M. (2002). Stabilization of Gas lift wells. *In Proceeding of the IFAC 15th World Congress*, Barcelona, Spain.
- Going, W.S, Thigpen, P.M, Anderson A.B. (2006). Intelligente Well Technology: Are We Ready for Closed Loop Control. *In SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers Inc.*, Paper number. SPE 99834.
- Hernández, G., Ali E., Sharon T., (2001). Manual del curso de levantamiento artificial por gas avanzado”. Segunda edición. PDVSA Intevep.
- Jansen, B. Dalsmo, L. Nokleberg, K. Kristiansen, and Lemetayer, P. (1999). Automatic control of unstable gas lifted wells. *In SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers Inc.*, Paper number: SPE 56832.
- Pérez Ana, Torres Elizabeth, Maldonado, Ronald, Rivas Francklin. (2005). Pisum Sativum Classification using discriminate analysis and Neural Networks. *6th WSEAS International Conference on Neural Networks*. Lisbon, Portugal.
- Salcedo, J, V., Martínez, M., (2006). Identificación de Modelos LPV para el Control de Sistemas No Lineales. *Revista Iberoamericana de Automática e Informática Industrial*. ISSN: 1697-7912. Vol.3, Núm 3, pp 92-107.
- Takeshi Yamakawa (1994). A neo Fuzzy Neuron and Its Applications to System Identification and Prediction of Chaotic Behavior. IEEE.
- Vassileios D. Kosmidis, John D Pekins and Efstratios N Pistikopoulos., (2005). A mixed integer optimization and selection of intermittent gas lift methods a comprehensive model. *Journal of Petroleum fields, Computers & Chemical Engineering*, Volume 29, Issue 7, pages 123- 154.