

Determinación del Valor Óptimo de Gas de Inyección para un Sistema de Producción de Petróleo Crudo mediante Redes Neuronales

G. Jiménez de la Cruz^{1,2}, José A. Ruz Hernández¹, Evgen Shelomov¹,
Ruben Salazar Mendoza²

¹ Universidad Autonoma del Carmen, Av. 56 # 4 Esq. Av. Concordia, Col. Aviación, C.P. 24180, Cd. Del Carmen, Campeche México, email: {jruez, eshelomov}@pampano.unacar.mx

² Instituto Mexicano del Petroleo, Av. Periférica Norte # 75 Esq. Calle 35B, Col. San Agustín del Palmar, C.P. 24118, Cd. del Carmen, Campeche, México, e-mail: {gjcruz, rsalazar}@imp.mx, gjc@mexico.com

Resumen. En este artículo se propone una estrategia de optimización basada en redes neuronales. La estrategia se utiliza para determinar los valores óptimos de la tasa de inyección de gas para un sistema de producción artificial de hidrocarburos. Se analizan dos casos; en el primero, se considera un sistema de producción con gas artificial de un solo pozo y en el segundo se considera un sistema de producción compuesto por dos pozos. Para ambos casos, se minimiza una función objetivo o de costo. La estrategia propuesta pone de manifiesto la habilidad de las redes neuronales para aproximar el comportamiento de un sistema de producción de petróleo crudo y para resolver problemas de optimización cuando un modelo matemático no está disponible.

Palabras Claves: Redes neuronales, sistemas de producción de hidrocarburos, gas de inyección, optimización y perceptrón multicapa.

1 Introducción

La operación de los sistemas de producción de gas y petróleo crudo, requiere de muchas decisiones que deben tomarse afectando los volúmenes producidos y el costo de producción. Estas decisiones se toman a diferentes niveles en la organización de las empresas relacionadas con el petróleo, pero con el tiempo repercuten en el sistema físico de producción [1]. La Fig. 1 ilustra la visión general de un sistema físico de producción con gas de inyección de levantamiento. Para este tipo de sistemas de producción de petróleo crudo, las variables de decisión se relacionan para encontrar el flujo de gas de levantamiento para cada pozo que entregará un flujo máximo de producción total de petróleo crudo en un pequeño instante de tiempo.

Una función objetivo es un valor único y una función matemática bien definida que mapea los valores de las variables de decisión y se ubican dentro de una medida del comportamiento. Ejemplos de tales medidas de comportamiento son, el flujo de la producción total de petróleo crudo, el valor actual neto (ganancia) o la recuperación del yacimiento. En el esfuerzo hacia un mejor comportamiento del sistema de producción, una pregunta que comúnmente debe agregarse, consiste en decidir cuál de las decisiones será mejor para maximizar o minimizar la función objetivo.

*M.A. Moreno, C.A.Cruz, J. Álvarez, H. Sira (Eds.)
Special Issue: Advances in Automatic Control and Engineering
Research in Computing Science 36, 2008, pp.127-136*




Fig. 1. Sistema de producción con gas de levantamiento de un solo pozo.

El objetivo del gas de levantamiento es incrementar la producción de Petróleo crudo o evitar el decremento de flujos en los pozos mediante la reducción de la cabeza hidrostática de la columna del fluido en el pozo [2]. Mediante la inyección de gas dentro de la tubería, la densidad del fluido disminuye en el agujero del pozo; por lo tanto, la componente de caída de presión resultante de la gravedad se reduce. Sin embargo, el gas de levantamiento también proporciona un componente más grande de caída de presión resultante de la fricción, dando una pequeño flujo de gas óptimo de levantamiento para el pozo. Por lo general la disposición de gas de levantamiento para un grupo de pozos es inferior a la suma de los flujos individuales de gas óptimo de levantamiento para cada pozo. El problema de optimización con gas de inyección de levantamiento consiste en encontrar los flujos de gas de levantamiento para cada pozo entregando el flujo máximo total de producción de petróleo crudo sujeto a restricciones en la capacidad de procesamiento del gas de inyección de levantamiento y otras posibles operaciones.

En el presente trabajo, una estrategia de optimización basada en redes neuronales se desarrolló y aplicó para calcular los valores óptimos de flujos de gas de inyección y de petróleo crudo de un sistema de producción de gas de levantamiento. Se analizaron dos casos; en el primero, se considera optimizar un sistema de producción con gas de levantamiento de un solo pozo y en el segundo, se considera un sistema de producción con gas de levantamiento compuesto por dos pozos. Para ambos casos se minimiza una función objetivo. La estrategia propuesta muestra la habilidad de las redes neuronales para aproximar el comportamiento de un sistema de producción de petróleo crudo y para resolver problemas de optimización cuando un modelo matemático no está disponible.

2 Estrategia de Optimización basada en una Red Neuronal

Con el fin de resolver el problema de optimización gas-levantamiento, se desarrolló un procedimiento de optimización basado en redes neuronales que consta de dos componentes (ver Fig. 2). Las dos componentes son la red neuronal utilizada para aproximar la curva de comportamiento de gas de levantamiento y la función objetivo para satisfacer un índice de rendimiento.

El tipo de red neuronal empleado en la estrategia es del tipo Perceptrón Multicapa (MLP). Este tipo de redes neuronales presentan flexibilidad y excelentes propiedades para aproximar funciones. La siguiente ecuación se utiliza para determinar la estructura de una MLP con M neuronas en una sola capa oculta o intermedia con función de activación sigmoideal y una neurona en la capa de salida con función de activación lineal.

$$F(x_1, \dots, x_p) = \sum_{i=1}^M \alpha_i g\left(\sum_{j=1}^p w_{ij} x_j - \theta_i\right) \quad (1)$$

La mayoría de los autores e investigadores en redes neuronales han llegado a la conclusión que las redes neuronales de dos capas que utilizan funciones de activación del tipo tangente hiperbólica o de tipo sigmoideal en la capa intermedia son aproximados universales [3] y [4]. Las redes neuronales multicapa pueden diseñarse y entrenarse con la ayuda del Toolbox de Redes neuronales que se utiliza con Matlab ®. Los datos de entrenamiento se colectan a partir de una curva de comportamiento de gas de levantamiento obtenido de un simulador de pozos [5]. En este caso, la expresión que corresponde a la red neuronal empleada para aproximar el flujo de petróleo crudo producido por el sistema es

$$Q_{est}(k) = g[Q_{iny}(k-1)] \quad (2)$$

donde $Q_{iny}(k) \in \mathfrak{R}$ es el flujo de gas-levantamiento inyectado dentro del pozo y $Q_{est}(k) \in \mathfrak{R}$ es el flujo estimado de petróleo crudo producido.

En esta aplicación, el procedimiento de aproximación se realiza mediante el entrenamiento de una red neuronal perceptrón de tres capas. La capa oculta contiene neuronas usando función de activación sigmoideal y la capa de salida contiene una única neurona con función de activación lineal. Diferentes MLPs son entrenaron mediante el algoritmo de Levenberg-Marquardt, que utiliza el criterio del error cuadrático medio para actualizar los pesos de la red neuronal. La correspondiente red MLP se ilustra en la Fig. 3. La expresión que define la función objetivo usada en la estrategia de optimización está dada por:

$$J(u_k) = \alpha_k [Q_{est}(k) - ref(k)]^2 + \beta_k (\Delta u_k)^2 \quad (3)$$

donde $Q_{est}(k)$ es la aproximación de la red neuronal del flujo de petróleo crudo producido (BPD). $ref(k)$: Referencia del flujo de Petróleo crudo producido (BPD).

u_k : Flujo de inyección actualizado (MMpcd). $\Delta u_k = u_k - u_{k-1}$, α_k : Peso del error cuadrático del Flujo de Petróleo crudo producido. β_k : Es el peso del esfuerzo de control.

Con el fin de minimizar la función objetivo, se calcula una tasa de gas de inyección óptima variando la tasa de gas de acuerdo a (4) en el intervalo dado en (5) y evaluando cada valor en la función objetivo de tal modo que por comparación entre una evaluación y otra se localiza el valor del flujo de gas que minimiza la función objetivo (3), [6]. Al flujo de gas variante lo denotaremos como u_{opt} .




Fig. 2. Estrategia de Optimización basada en una Red Neuronal.




Fig. 3. Red Neuronal MLP

El número de variaciones que tomará u_{rab} en el intervalo dado en (5), con incrementos de Δ será $nit = (M / 0.01) + 1$, recordando que la precisión considerada con que cuenta el instrumento es de 1% después del punto decimal. La Fig. 4. muestra el diagrama de flujo correspondiente al procedimiento de optimización donde u_{max} : Flujo óptimo de gas de inyección (MMpcd), nit : Numero de variaciones del flujo de inyección, u_n : Flujo de gas de inyección inicial (MMpcd), min : Valor mínimo de la función objetivo utilizado en el procedimiento de optimización, $J_{(urab)}$: Valor que adquiere la función objetivo en cada iteración, $iter$: Contador de iteraciones en la rutina de optimización, u_{opt} : Registro para almacenar el valor actual de la tasa óptima de gas de inyección (MMpcd), P_{optim} : Registro que almacena el valor actual de flujo de petróleo crudo correspondiente al Flujo de gas de inyección óptimo, Q : Flujo de Petróleo crudo producido una vez evaluado u_{opt} en el modelo considerado (BPD).

Para resolver el problema de optimización numérica, se tienen las siguientes consideraciones:

- Dada la medida de precisión del instrumento sensor usado en esta aplicación, se considera una unidad porcentual de flujo de inyección de gas nominal, al paso de gas de inyección empleado en la optimización para determinar el flujo de gas de inyección óptimo el cual esta dado por:

$$\Delta Q_{iny}(k) = 1\% = 0.01 \quad (4)$$

- El flujo de inyección de gas será un valor en el siguiente intervalo [MMpcd]:




Fig. 2. Diagrama de flujo correspondiente al procedimiento de optimización.

$$0.0 \leq Q_{inj}(k) \leq Q_{inj, \max} \quad (5)$$

- No se cuenta con un modelo matemático del proceso; sin embargo, se cuenta con datos experimentales de un simulador de pozos tomados en un solo intervalo de tiempo de periodo relativamente grande. Por lo que, se dispone de un modelo neuronal del proceso, el cual será utilizado para aproximar este comportamiento y construir la función objetivo.
- Es importante definir el número de variaciones del flujo de gas de inyección (*nit*). Este número se calcula como:

$$nit = \left(\frac{M}{\Delta} \right) + 1 \quad (6)$$

donde M : límite máximo de gas de inyección con $\Delta = 0.01$.

- Partiendo de los datos experimentales de la curva de producción podemos definir una función vectorial continua en el tiempo $\varphi(k)$ cuyos elementos sean los valores de referencia de gas de inyección y petróleo crudo producido en el instante t .

Tomando en cuenta las consideraciones anteriores, podemos formular el siguiente problema de optimización como sigue:

$$\text{Min } J(v(k)) = \|\varphi(k) - \varphi_{est}(k)\| \quad (7)$$

donde:

$$v(k) = [Q_o(k), Q_{iny}(k)]^T \in \mathfrak{R} \quad (8)$$

Ahora, escribiremos la ecuación (8) como sigue:

$$J(v(k)) = \{\alpha_k [Q_o(k) - Q_{oh}(k)]^2 + \beta_k [Q_{iny}(k) - Q_{iny}(k-1)]^2\} \quad (9)$$

En la expresión anterior, los coeficientes α_k y β_k se emplean para equilibrar las unidades de flujo de gas de inyección y de petróleo crudo. Con el fin de minimizar la función de objetivo dada en (9), debemos variar el flujo de gas de inyección y de petróleo crudo evaluando este par ordenado, de tal forma que mediante comparaciones secuenciales entre las evaluaciones, se localicen los valores óptimos de $Q_{iny}(k)$ y $Q_o(k)$.

3 Aproximación Neuronal del Flujo de Petróleo crudo

Aquí se consideran dos casos; en el primero, un modelo de red neuronal aproxima el flujo de petróleo crudo producido para un solo pozo y en el segundo un modelo de red neuronal aproxima el flujo de petróleo crudo producido para un sistema de producción de dos pozos. Los resultados obtenidos se presentan a continuación.

Caso 1: Sistema de producción de un solo pozo. El sistema de producción de petróleo crudo se ilustró en la Fig. 1. En este caso, el vector de entrada $\varphi(k)$ se genera considerando una presión en la cabeza del pozo igual a 12 kg/cm². En la Fig. 5 se muestran los datos de entrenamiento que fueron colectados utilizando el simulador de pozos PROSPER[®], 600 pares de muestras de datos experimentales de gas de inyección se utilizan y se toman en el intervalo $0.0 \leq Q_{iny} \leq 6.0$. En la Fig. 6 se muestran los datos de entrenamiento que corresponden al flujo de petróleo crudo producido en unidades BPD (Barriles estándar por día).

En este caso, la red neuronal se entrena para aproximar el flujo de petróleo crudo producido para un único pozo. Las características de la mejor red neuronal entrenada se describe en la Tabla 1 y el error obtenido se muestra en la Fig. 7.

Tabla 1. Arquitectura de la red neuronal y errores obtenidos, caso 1

Numero de neuronas		error	error (%)
Capa intermedia	Capa de salida		
30	1	0.0119	0.0004

La aproximación llevada a cabo mediante la red neuronal se compara con el flujo de datos experimentales de petróleo crudo producido por el pozo (ver Fig. 8).

Caso 2: Sistema de producción basado en dos pozos. En la Fig. 9 se muestra un sistema de producción de petróleo crudo de dos pozos. El vector de entrada $\varphi(k)$ se generó considerando una presión en la cabeza de cada pozo de 12 k g/cm² y 14 kg/cm², respectivamente.




Fig. 5. Datos experimentales de flujo de gas de inyección.






Fig. 6. Datos experimentales de flujo de producción de petróleo crudo.



(7a)



(7b)

Fig. 7. Resultados para el caso 1, (a) error, (b) porcentaje de error.




Fig. 8. Resultado Comparación entre las aproximaciones logradas utilizando el modelo de red neuronal (línea sólida) y datos experimentales (marcas redondas) del sistema de un solo pozo.

En la Fig. 10 se muestran los datos de entrenamiento, para lo cual se consideran 600 pares de muestras de datos experimentales de gas de inyección y se toman en un intervalo de gas producido de $0.0 \leq Q_{iny} \leq 12.0$. La red neuronal se entrena para aproximar el flujo de petróleo crudo producido por el sistema. Como en el caso anterior, después del entrenamiento y validación, una red neuronal se selecciona considerando su desempeño y complejidad. La mejor red neuronal entrenada se

describe en la Tabla 2. Se muestran los datos de entrenamiento que corresponden al flujo de petróleo crudo producido en unidades BPD.




Fig. 9. Sistema de producción compuesto por dos pozos.




Fig. 10. Datos experimentales de flujo de gas de inyección.





Fig. 11. Valores para la validación


Tabla 2. Arquitectura de la red neuronal y errores obtenidos, caso 1

Número de neuronas		error	error (%)
Capa intermedia	Capa de salida		
30	1	-0.3702	-0.0037

En la Fig. 12 se muestran el error obtenido utilizando la red neuronal descrita en la Tabla 2. La aproximación obtenida con la red se compara con el flujo de datos experimentales de petróleo crudo para un sistema compuesto por dos pozos (Fig. 13).



(12a)



(12b)

Fig. 12. Resultados para el caso 2, (a) error, (b) porcentaje de error.




Fig. 13. Resultado de la comparación entre las aproximaciones (línea sólida) y los datos experimentales (marcas redondas) para un sistema de dos pozos.

4 Aplicación de la Estrategia Neuronal de Optimización

Una vez que ambos sistemas son aproximados usando redes neuronales, la siguiente etapa se establece y se resuelve el problema de optimización como sigue.

Caso 1: Sistema de un solo pozo. El procedimiento se utiliza para determinar el flujo de gas de inyección óptimo. Cuando la iteración 93, se lleva a cabo el flujo óptimo de gas de inyección obtenido es 0.93 MMpcd (Ver Fig. 14). Este flujo se evalúa en la red neuronal descrita en la tabla 1 para obtener una producción de 3102.8 BPD. En la Fig. 15 se muestra como la función objetivo se minimiza.




Fig. 14. Gas de inyección óptimo caso 1




Fig. 15. Función objetivo minimizada

Caso 2: Sistema de producción basado en dos pozos. El procedimiento de optimización se utiliza ahora para determinar el flujo óptimo de gas de inyección. Cuando la iteración 349, se lleva a cabo el flujo óptimo de gas de inyección obtenido es 6.98 MMpcd (Ver Fig. 16). Este flujo se evalúa en la red neuronal descrita en la Tabla 2 para obtener una producción de 10087.0 BPD. En la Fig. 17 se muestra como la función objetivo es minimizada.

5 Conclusiones

En este trabajo una estrategia de inteligencia computacional basada en redes neuronales se propone para optimizar la tasa de gas de inyección requerido a inyectarse en un sistema de producción de hidrocarburos.




Fig. 16. Gas de inyección óptimo caso 2




Fig. 17. Función objetivo minimizada

Una vez que la tasa óptima es determinada y aplicada al sistema de producción, los resultados de simulación obtenidos se aproximan a la referencia de petróleo crudo producido. La estrategia propuesta pone de manifiesto la habilidad de las redes neuronales para aproximar el comportamiento de un sistema de producción de petróleo crudo y para resolver problemas de optimización cuando un modelo matemático no está disponible. Es justo mencionar que esta metodología puede utilizarse como un mecanismo de ayuda para ingenieros de producción. Los investigadores están motivados a extender el presente trabajo mediante la optimización con algoritmos genéticos.

6 Agradecimientos

Los autores agradecen el apoyo de la UNACAR a través del proyecto PR/131/2008.

7 Referencias

1. Bieker H.P., Slupphaug, O. and Johansen, T. A., "Real-Time Production Optimization of Oil and Gas Production Systems: A Technology Survey," *SPE Production & Operations Journal*, vol. 22, no. 4, pp. 382-391, November 2007.
2. Vasper, A., "Auto, Natural, or In-Situ Gas-Lift Systems Explained," *SPE Production & Operations Journal*, vol. 23, no. 1, pp. 75-80, February 2008.
3. Hornik, K., Stinchcombe, M. and White H. "Multilayer Feedforward Networks are Universal Approximators", *Neural Networks*, vol. 2, no. 5, 1989.
4. Norgaard, M. Ravn, O.; Poulsen, N. K., y Hansen, L. K., "Neural Networks for Modelling and Control of Dynamic Systems", Springer-Verlag, London, 2000.
5. Prosper. Petroleum Experts Ltd. User Guide IPM V5.3Build #173 Jun 6, 2006.
6. Ruz-Hernandez Jose A., Suarez D. A., Shelomov E. and Villavicencio A., "Predictive Control Based on an Auto-Regressive Neuro-Fuzzy Model Applied to the Steam Generator Startup Process at a Fossil Power Plant", *Revista de Computación y Sistemas*, vol. 6, no. 3, CIC-IPN, ISSN 1405 5546, Mexico, pp.204-212, 2003.160, 1987.
7. Sánchez E. N., M.C. Alanís G A.. *Redes Neuronales "Conceptos Fundamentales y Aplicaciones al Control Automático"*. Cinvestav Unidad Guadalajara. Editorial Prentice Hall.