INVERSIÓN SÍSMICA DE UN MODELO TEÓRICO CALCULADO SOBRE UN HORIZONTE SÍSMICO UTILIZANDO REDES NEURONALES

CERSOSIMO DARIO SERGIO (1), CLAUDIA RAVAZOLI (2), GARCIA MARTINEZ RAMON (3)
(1) Programa de Doctorado, Facultad de Ciencias Astronómicas y Geofísicas Universidad Nacional de La Plata Buenos Aires ARGENTINA, PETROBRAS ENERGÍA Exploración ARGENTINA
(2) Grupo de Geofísica Aplicada Facultad de Ciencias Astronómicas y Geofísicas Universidad Nacional de La Plata (1900) La Plata. Buenos Aires ARGENTINA
(3) Centro de Ingeniería del Software y del Conocimiento (CAPIS) Instituto Tecnológico de Buenos Aires (1106) Buenos Aires ARGENTINA.

ABSTRACT

Se describe trabajo experimental cuyos resultados permiten inferir que a partir de la sección sísmica y datos de pozo es posible determinar anomalías y variaciones de velocidades en capas con espesores muy por debajo de la resolución sísmica utilizando prospectiva de datos faltantes basada en redes neuronales.

1. INTRODUCCIÓN

Los sistemas inteligentes [Holland *et al.*, 1987; Towell & Shavlik, 1994; García-Martínez & Borrajo, 2000] han mostrado ser de suma utilidad en problemas prospectivos en los que otros enfoques han fallado. En particular, las Redes Neuronales como un caso particular de los sistemas inteligentes [Hertz *et al.*, 1991; Rich & Knight, 1991; Setiono & Liu, 1996; Yao & Liu, 1998; Haykins, 1999], han dado resultados prometedores en campos como: modelado, análisis de series de tiempo, reconocimiento de patrones entre otros [Dow & Sietsma, 1991; Gallant, 1993; Back *et al.*, 1998]. En el campo de las geociencias este tipo de sistemas han contribuido con desarrollos convencionales y no convencionales de interpretación y procesamiento [Heggland *et al.*, 1999a; 1999b; 2000; An & Moon, 1993; Johnston, 1993; Wang & Huang, 1993; Ping, 1994; Cai, 1994; Huang & Williamson, 1994; Zhang *et al.*, 1995a; 1995b].
En esta publicación se describe trabajo experimental cuyos resultados permiten inferir que a partir de la sección sísmica y datos de pozo es posible distinguir o inferir anomalías y variaciones de velocidades en capas con espesores muy por debajo de la resolución sísmica utilizando prospectiva de datos faltantes basada en redes neuronales.

2. TRATAMIENTO DE LOS DATOS

Para el tratamiento experimental se ha partido de un modelo geológico. A este modelo geológico se le ha calculado una sección sísmica (método directo). Se ha utilizado un modelo geológico de capas paralelas. A estas capas se le han asignado velocidades de arenas con gas y arenas con petróleo. Como se observa en la figura 1 tenemos cinco capas de las cuales la tercera (amarilla) es una capa del orden de los diez metros de espesor. Esta capa posee variación lateral y vertical de velocidades (Tabla 1).

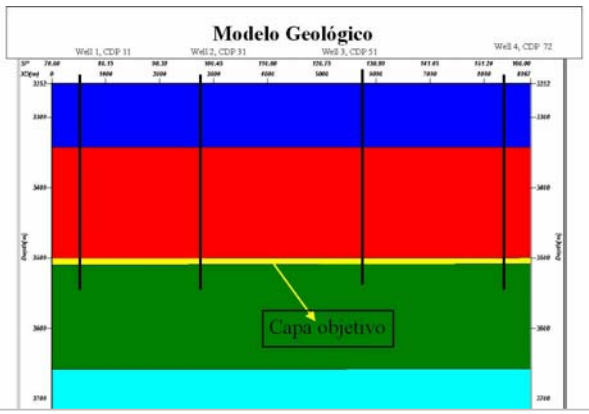

Figura 1: Modelo Geológico

Campo de velocidades

NAME	PATTERN		DIST	VTOP	VBOT	DTOP	DBOT
C1			0.00	3500.00	3500.00	2375.724	2375.724
			8866.80	3500.00	3500.00	2375.724	2375.724
C2			0.00	3500.00	3500.00	2375.724	2375.724
			8866.80	3500.00	3500.00	2375.724	2375.724
C3	CDP 11	Well 1	0.00	3467.00	3467.00	2370.104	2370.104
			2000.00	3467.00	3467.00	2370.104	2370.104
	CDP 31	Well 2	2500.00	3380.00	3467.00	2355.093	2370.104
			3000.00	3380.00	3467.00	2355.093	2370.104
			3500.00	3467.00	3467.00	2370.104	2370.104
			5000.00	3467.00	3467.00	2370.104	2370.104
	CDP 51	Well 3	5500.00	3380.00	3467.00	2355.093	2370.104
			6000.00	3380.00	3467.00	2355.093	2370.104
	CDP 72	Well 4	6500.00	3467.00	3467.00	2370.104	2370.104
			8866.80	3467.00	3467.00	2370.104	2370.104
C4			0.00	3800.00	3800.00	2425.073	2425.073
			8866.80	3800.00	3800.00	2425.073	2425.073
C5			0.00	3900.00	3900.00	2440.873	2440.873
			8866.80	3900.00	3900.00	2440.873	2440.873
			m	m/seg	m/seg	$g/cm^{-3}10^{-3}$	

Tabla 1: Campo de velocidades

Donde DIST es la distancia desde el origen, VTOP es la velocidad del tope de la capa, VBOT es la velocidad de la base de la capa, DTOP es la densidad del tope de la capa y DBOT es la densidad de la base de la capa.Las densidades involucradas se calculan con la ecuación de Gardner [Gardner, G.H.F., Gardner, L.W., and Gregory, A.R., 1974,]. Este modelo geológico es el que se utiliza para el cálculo de la sección sísmica sintética (figura 2).

Los parámetros que se usan para el cálculo de la sección sísmica sintética son los descriptos en la Tabla 2. El contenido en frecuencia de la sección sísmica sintética hace imposible determinar el tope y la base del horizonte objetivo (amarillo) debido a las frecuencias elegidas para el cálculo de la ondícula.

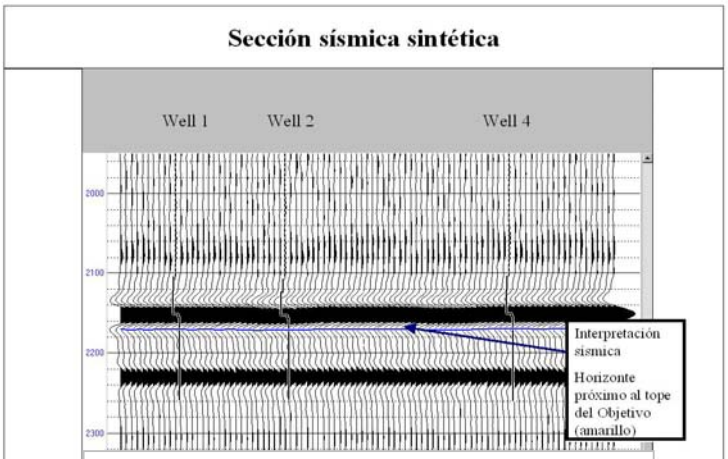

Figura 2: Sección Sísmica Sintética

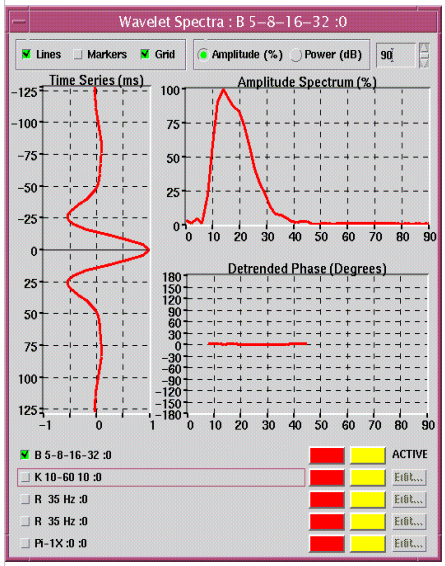

Start Trace	1
End Trace	91
Trace Increment	1
Trace Amplitude	1.00
Sample Rate	2.00
Start Shot Pt.	70.00
End Shot Pt.	160.00
Shot Pt. Space	98.52
Shot Pt. Incr.	1.00
WAVELET	ORMSBY
Frequency 1	5.0
Frequency 2	8.0
Frequency 3	16.0
Frequency 4	32.0
Phase (M=min)	0.0

Tabla 2: Ondícula y parametros elegidos parta el cálculo de la Sección Sísmica Sintética

La variación de velocidades sobre el horizonte real se muestran en la Figura 3.

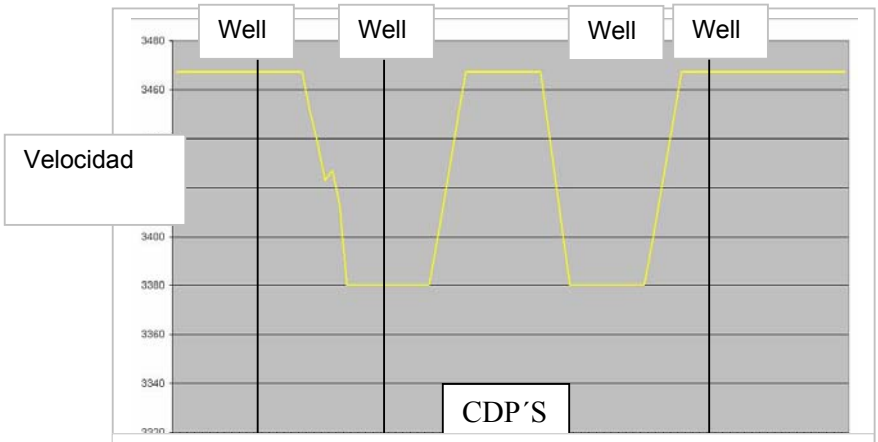

Figura 3: Variación de Velocidades sobre el Horizonte Real

3. INVERSIÓN DE TRAZA CONVENCIONAL

En este abordaje (model Based), [Russell, B.H., 1988, Introduction to Seismic Inversion Methods] [Treitel, S, Larry Lines, and Gary Ruckgaber Geophysical Inversion and Applications, 1993 142 pages.] ,con el dato sísmico sintético y el dato de tres pozos (Well 1, Well 2 y Well 4) se procedió a procesar una inversión de traza convencional. Se tomó como sónicos los perfiles generados utilizando las velocidades del modelo geológico teórico. El modelo inicial (figura 4) fue la interpretación sísmica hecha en un horizonte que se presumía próximo al horizonte objetivo.

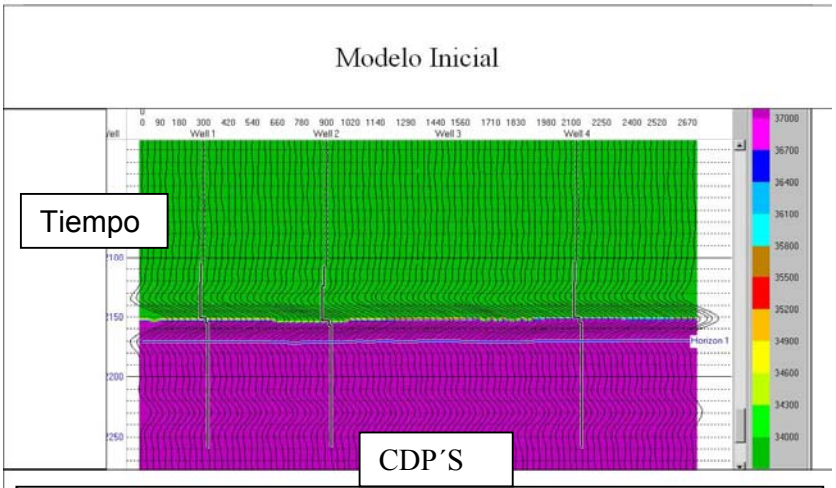

Figura 4: Modelo Inicial

Con un total de 50 iteraciones se llegó al resultado observado en la figura 5. Esta gráfica muestra la variación de velocidades dadas por la inversión Model Based analizadas en el horizonte de interés. En el se observa que la inversión ha podido discriminar dos zonas con bajas velocidades correspondientes a los pozos Well 2 y Well 3 respectivamente (2150 mseg.).

4. INVERSIÓN DE TRAZA USANDO UNA RED NEURONAL

En esta etapa, se aplicó una red neuronal al dato sísmico. La arquitectura elegida fue una Feed Forward Back Propagation [Freeman, James A., SKAPURA, David M.], definida con nueve neuronas de input, una capa oculta de 5 neuronas y una neurona de salida. En la figura 6 se puede apreciar el diseño de la RNA(Red Neuronal Artificial) con sus entradas y la salida deseada.

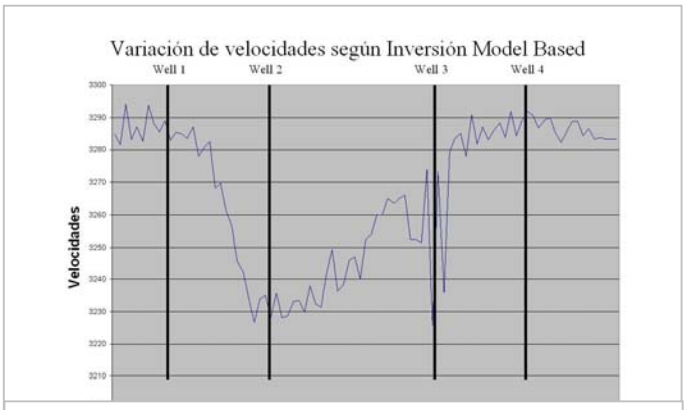

Figura 5: Variación de Velocidades sobre el Horizonte de Interés según Inversión Model Based

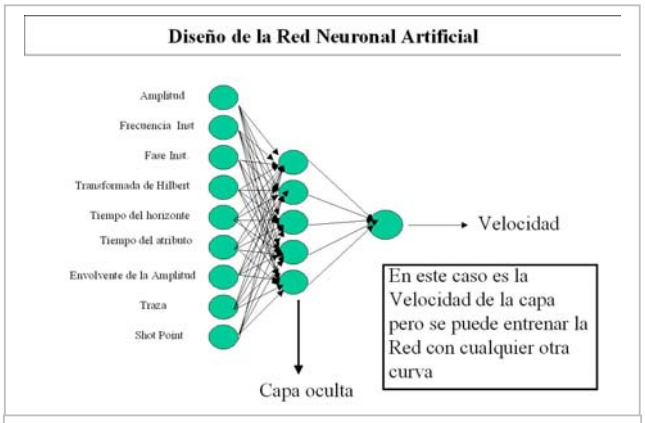

Figura 6: Diseño de la Red Neuronal Artificial

El dato de entrada comprendía la interpretación sísmica, atributos sísmicos calculados sobre el horizonte interpretado. El dato deseado fueron las velocidades de los pozos Well 1, Well 2, Well 4 (los mismos datos de entrada que en el caso de la inversión convencional). Se entrenó a la red con los datos de los tres pozos mencionados a los efectos de calcular la velocidad en cada traza de la sección sísmica con un error menor que el 1 % y 1000 iteraciones.

Se obtuvo una representación de la velocidad del horizonte en función de los Shots Points (SP) y CDP´s (fig. 7)

Comparada la Variación de Velocidades sobre el Horizonte de Interés provista por el Model Based versus la provista por Redes Neuronales Artificiales (Figura 8), se puede observar que la RNA ha podido discriminar dos zonas bien definidas de baja velocidad. La primera se encuentra entre los CDP's 22 y 37, correspondiente al pozo Well 2, y la segunda entre los CDP's 52 y 70, correspondiente al pozo Well 3. Es importante destacar que esta última zona ha sido predicha por la RNA con éxito debido a que el pozo Well 3 no se ha utilizado para el entrenamiento de la red, esto se puede corroborar observando el campo de velocidades dado en la Tabla 1. Para los intervalos de distancias comprendidos entre 2500m. a 3000m. y 5500m. a 6000m, la velocidad del tope del horizonte amarillo es del orden de los 3380m/seg. Correspondientes a los pozos Well 2 y Well 3 respectivamente

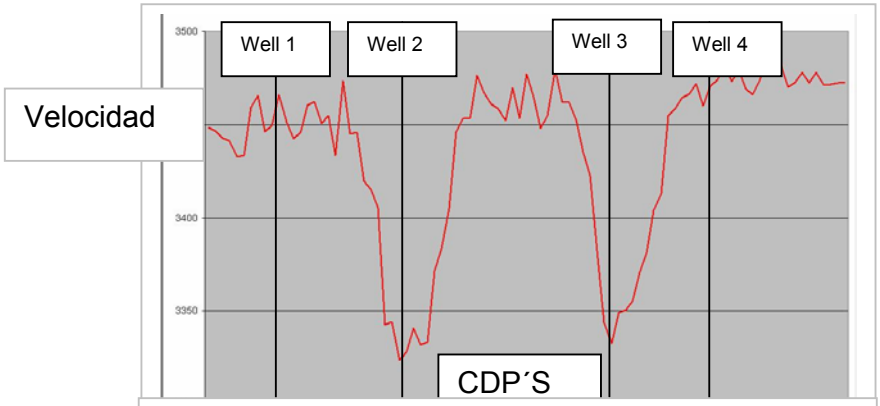

Figura 7: Variación de Velocidades sobre el Horizonte de Interés según Redes Neuronales Artificiales

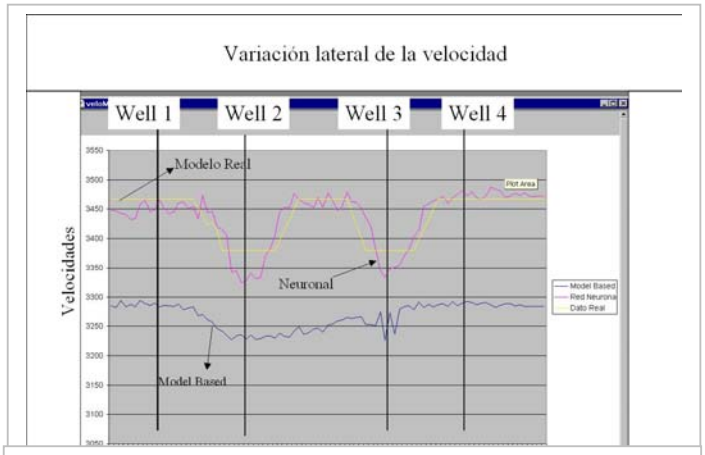

Figura 8: Comparación de Variación de Velocidades sobre el Horizonte de Interés

4. CONCLUSIONES

El objetivo experimental consistió en encontrar las variaciones de velocidad en la capa de menor espesor a partir de:

a) Los datos de la interpretación sísmica.
b) Los atributos sísmicos calculados en el horizonte sísmico interpretado (Amplitud, Frecuencia instantánea, Fase instantánea, Transformada Hilbert, Envolvente de la amplitud, traza sísmica).
c) Los datos de pozos.

Surge de la experimentación que la RNA ha podido discriminar mejor la baja velocidad que se observa en el pozo Well 3. De esta manera se puede inferir que es posible discriminar variaciones de velocidades, Impedancias Acústicas o cualquier otra curva obtenida de pozos a lo largo de una sección o cubo sísmico usando RNAs.

5. REFERENCIAS

An, P. and Moon, W. (1993). *Reservoir characterization using feedforward neural networks*. 63rd Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts, , 93, 258-262.

Cai, Y. (1994) *The artificial neural network approach for hydrocarbon prediction by synthesizing multiple seismic information*. 56th Mtg. Eur. Assoc. Expl. Geophys., Extended Abstracts, , 94, Session:P153.

Dow R. J. y Sietsma J. (1991) *Creating Artificial Neural Networks that Generalize*. Neural Networks, vol. 4, no. 1, pp. 198-209.

Back, B., Sere, K., & Vanharanta, H. (1998) *Managing complexity in large data bases using self-organizing maps*, Accounting Management & Information Technologies 8 (1998), 191-210.

Freeman, James A., SKAPURA, David M. Redes Neuronales Algoritmos Aplicaciones y Técnicas de Programación. Adison-Wesley Iberoamericana S.A. 1993.

Gallant, S. (1993) *Neural Network Learning & Experts Systems*. MIT Press, Cambridge, MA.

García Martínez, R. y Borrajo, D. (2000) *An Integrated Approach of Learning, Planning & Executing.* Journal of Intelligent & Robotic Systems. Vol. 29, Nber 1, Páginas 47-78. Kluwer Academic Press. 2000.

Gardner, G.H.F., Gardner, L.W., and Gregory, A.R., 1974, Formation velocity and density-the diagnostic basics for stratigraphic traps: Geophysics 39, 770-780.

Haykin S, (1999) *Neural Networks. A Comprehensive Foundation*. Second Edition. Pretince Hall.

Heggland, R., Meldahl, P., Bril, B. & de Groot, P., (1999a). *The chimney cube, an*

example of semi-automated detection of seismic objects by directive attributes neural networks: Part I;methodology, Expanded Abstracts of the SEG 69th Annual Meeting, Houston, Oct. 31 – Nov. 5,

Heggland, R., Meldahl, P., Bril, B. & de Groot, P., (1999b). *The chimney cube, an example of semi-automated detection of seismic objects by directive attributes & neural networks: Part II; interpretation*, Expanded Abstracts of the SEG 69th Annual Meeting, Houston, Oct. 31 – Nov. 5.

Heggland, R., Meldahl, P., de Groot, P. & Aminzadeh, F., (2000). *Chimneys in the Gulf of Mexico*, The American Oil & Gas Reporter, Feb. 2000.

Hertz J., A. Krogh y R. Palmer (1991) *Introduction to the Theory of Neural Computation*. Reading, MA: Addison-Wesley.

Hilera, José R. y Martínez, Víctor J. Redes Neuronales artificiales fundamentos y aplicaciones. Editor Adalison - Wesley Iberoamérica

Holland, J. H., Holyoak, K. J., Nisbett, R. E., & Thagard, P. R. (1987). *Classifier systems, Q-morphisms, & induction*. In L. Davis (Ed.), Genetic algorithms & simulated aneling pp. 116-128.

Huang, Z. & Williamson, M. (1994). *Geological pattern recognition and modelling with a general regression neural network*. Can. J. Expl. Geophys., 30, no. 1, 60-68.

Jacek M. Zurada: Introduction to Artificial Neural Systems,West Publishing Company, 1995.

Johnston, D. (1993). *Seismic attribute calibration using neural networks*. 63rd Annual Internat. Mtg., Soc. Expl. Geophys., ExpandedAbstracts, , 93, 250-253.

Ping A. (1994). *The effect of random noise in lateral reservoir characterization using feed- forward neural networks* Geological Survey of Canada. 1994

Rich E. y Knight, K. (1991) *Introduction to Artificial Networks*. Mac Graw-Hill. Publications.

Russell, B.H., 1988, Introduction to Seismic *Inversion Methods*: Society of Exploration Geophysicists.

Setiono R. & Liu. H. (1996) *Symbolic representation of neural networks*. IEEE Computer Magzine, pag. 71-77, 1996.

Stewart, R.R., Huddleston, P.D. and Tze Kong Kan, 1984, *Seismic versus sonic velocities: A vertical seismic profiling study*: Geophysics, 49,1153-1168.

Towell G. & Shavlik, J. (1994) *Knowledge-based artificial neural networks*. Artificial Intelligence, vol. 70, no. 1--2, pp. 119-165..

Treitel, S, Larry Lines, and Gary Ruckgaber Geophysical Inversion and Applications, 1993 142 pages.

Treitel, S & Essenreiter, R. (1995). *Predictive Deconvolution Revisited with Neural Nets*: 57th Mtg. Eur. Assoc. Expl Geophys. Extended Abstracts, 95, Session:P065.

Wang, J. & Huang, Z. (1993). *Neural networks for robust recognition of seismic reflection patterns*. 63rd Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts, , 93, 246-249.

Yao X. y Liu Y. (1998) *Toward Designing Artificial Neural Networks by Evolution*. Applied Mathematics & Computation, 91(1): 83-90.

Zhang, X., Li, Y., Hu, Q. & Feng, D. (1995a). *Early-stage reservoir analysis with SOMA: A neural network approach*. 65th Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts, , 95, 138-141.

Zhang, X., Li, Y., Liu, F. & Wang, L. (1995b). *Estimating reservoir's lithological parameters from seismic data using neural network*. 65th Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts, , 95, 606-608.

Zhou Chengdang et al.: “Application of Back-propagation Neural Networks and Simulated Annealing Technique to Well Log Interpretation,” Well Logging Technology, Vol. 17, No.4, 1993.