

Obtención de la velocidad de corte y parámetros elásticos- geomecánicos, utilizando redes neuronales

Daniel López Aguirre

Universidad Nacional Autónoma de México

Silvia Raquel García Benítez

Universidad Nacional Autónoma de México

Rubén Nicolás López

Instituto Mexicano del Petróleo

Artículo recibido en enero de 2020 y aceptado en marzo de 2020

Resumen

La velocidad de ondas de corte o cizalla y los parámetros elásticos como el módulo de Young (E), relación de Poisson (ν), módulo volumétrico (k), módulo de corte (μ) y parámetro de Lamé (λ) son insumos útiles y necesarios en el análisis de geomecánica del subsuelo, ya que con esta información se generan diversas posibilidades de análisis del subsuelo y se logra robustecer el espectro de decisiones durante las etapas de perforación y terminación de pozos petroleros.

No obstante, la importancia de esta información en muchas ocasiones no se tiene disponible. Para resolver esta problemática, se han seleccionado y emulado de la literatura, varias correlaciones que aproximan el comportamiento de la velocidad de corte y los parámetros elásticos en el subsuelo. Sin embargo, no en todos los casos se logra tener una aproximación aceptable con estas correlaciones.

Con la aplicación de esta metodología, fue posible generar los productos necesarios para la construcción de un modelo dinámico de geomecánica profunda, a partir de insumos comunes para la mayoría de los pozos estudiados, como son curvas de registros convencionales de rayos gamma, resistividad verdadera, tiempo de tránsito y densidad volumétrica; esta información se introdujo en un simulador de inteligencia artificial, que resolvió con las redes neuronales entrenando primeramente con valores conocidos, y posteriormente aplicando esta lógica a los casos objetivo.

Con base en esta metodología, se discretizó la velocidad de corte y los parámetros elásticos que forman parte del modelo geomecánico, optimizando con esto, los costos de consumo de horas/equipo generadas con adquisición de registros especializados como el sónico dipolar; además de que se puede ampliar para la obtención de otros parámetros de resistencia del medio roca-fluido, haciendo rentable la metodología en muchos aspectos.

Palabras clave: Velocidad de corte, parámetros elásticos, geomecánica profunda, inteligencia artificial, redes neuronales.

Estimation of shear velocity, elastic and geomechanical parameters by using neural networks

Abstract

Shear wave velocity and elastic parameters called Young's modulus (E), Poisson's ratio (ν), bulk modulus (k), shear modulus (μ) and Lamé parameter (λ) are useful and mandatory data for geomechanical analysis. Once this information is obtained, various choices of analysis are generated, and then we are also able to strengthen the variety of decisions on oil-well drilling and completion.

Unfortunately, this well information is often not available. To solve this drawback, several published correlations approximate the behavior of the shear velocity and the elastic parameters at depth; here they have been selected and emulated from the literature. However, for all cases, a proper accuracy cannot be attainable by using these correlations.

From the application of this methodology, we were able to estimate the parameters to develop a dynamic model for deep geomechanics from well-known data of the wells, such as curves of conventional logs: gamma ray, true resistivity, transit time and bulk density. An artificial intelligence simulator was fed up with this information, which was solved by applying neural networks. First, they were trained from known values, and after applying this logic process on the case study.

On the basis of this methodology, shear velocity and elastic parameters, that are part of the geomechanical model, were discretized. The results were the optimization of the consumption costs of hours / equipment generated with the acquisition of specialized records such as dipole sonic. In addition, it can be extended to obtain other strength parameters of the rock-fluid media, making the methodology profitable in many aspects.

Keywords: Shear wave velocity, elastic parameters, deep geomechanics, artificial intelligence, neural networks.

Introducción

La velocidad de ondas de corte o cizalla (V_s), y en consecuencia los parámetros elásticos (E, ν, K, μ y λ), son útiles en diversas aplicaciones de ingeniería petrolera, sin embargo, en muchas ocasiones esta información no está disponible debido entre otras causas, a la rapidez con la que se desea incorporar producción de los pozos petroleros o simplemente porque representan un costo mayor respecto a la toma de los registros convencionales, que los operadores no siempre tienen oportunidad de adquirir.

Existen numerosas áreas de aplicación en las que se incluyen tanto la V_s como los parámetros elásticos en ingeniería petrolera. Por ejemplo, autores como Nicolás-López y Valdiviezo-Mijangos (2015), generaron plantillas ternarias para distintas litologías a partir de la densidad volumétrica (ρ), en conjunto con parámetros elásticos como Módulo de Young (E), Relación de Poisson (ν), Módulo de Corte (μ) y Parámetro de Lamé (λ), con lo que ha sido posible identificar propiedades mecánicas de las rocas, porcentajes de diferentes minerales de componentes de las rocas sedimentarias como arcilla, calcita y cuarzo, así como el contenido de fluidos como pueden ser agua de formación, aceite, kerógeno o gas. Muchas de estas aplicaciones en numerosos casos no se discretizan a partir de ensayos petrofísicos comunes.

En este artículo se propone dar una solución alterna a la necesidad de obtener valores de V_s, E, ν, K, μ y λ , con

herramientas de avanzada (cómputo cognitivo) que permiten estudiar las condiciones a las que responden los valores de estos parámetros, en entornos de cálculo flexibles, adaptativos y con gran poder de interpretación-aproximación numérico/lingüística.

Obtención de la velocidad de corte (V_s) medida y a partir de correlaciones

La curva de velocidad de corte es un suministro importante para la evaluación geomecánica de pozos; aunque como se ha comentado, no siempre se tienen disponibles datos medidos (sin duda siempre será mejor contar con ellos).

La medición de la V_s en campo, se realiza con una herramienta de registros geofísicos conocida como *DSI* (Dipole Shear Sonic Imager), con la que se obtienen datos de las velocidades compresional y de corte.

Las aplicaciones principales para las mediciones del *DSI*, en conjunto con los usos típicos de los datos compresionales (*DTCO*), son las siguientes (Ramos, 2008):

- Análisis de propiedades mecánicas: análisis de la estabilidad del pozo, análisis de estabilidad de disparos, arenamiento, y diseño de un fracturamiento hidráulico.
- Evaluación de formaciones: detección de gas, detección y evaluación de fracturas naturales, así como la anisotropía de la permeabilidad.

- Interpretación geofísica: sismogramas sintéticos de onda P y onda S , diseño de VPS (vertical seismic profiling) y calibración de modelos AVO para análisis (amplitude variation with offset).
- Análisis de anisotropía de onda S : combinando con datos petrofísicos, geológicos y de ingeniería de yacimientos, es posible diseñar disparos orientados, optimización de la distribución de pozos, detección de zonas fracturadas en agujero descubierto o revestido, determinación de la trayectoria óptima de perforación en pozos de alto ángulo.

En los casos en que no se cuente con la información del registro DSI , en la literatura se pueden encontrar varias correlaciones con las que es posible obtener una curva de velocidad de corte sintética que, con la reserva adecuada, puede ofrecer una buena estimación ante la escases o indisponibilidad de datos medidos. En la **Tabla 1**, se presenta una recopilación de las correlaciones para obtener V_s .

Correlación	Ecuaciones	Aplicación
Empírica Petrofísica	$V_p = \sqrt{3} * V_s$ [Km/s]	Empírica Vp
	$V_s = 0.5774 * V_p$ [Km/s]	Empírica Vs
Empírica Picket (1963)	$V_s = 0.5263 * V_p$ [Km/s]	Calizas
	$V_s = 0.5556 * V_p$ [Km/s]	Dolomías
Castagna (1985)	$V_s = 0.862 * V_p - 1.172$ [Km/s]	Todas las litologías
	$V_s = 0.794 * V_p - 0.787$ [Km/s]	Areniscas saturadas
Eberhart-Phillips (1989)	$V_p = 5.77 - 6.94 * \phi - 1.73 * (V_{SH})^{0.5} + 0.446 * (\sigma_{ef} - 1 * e^{-16.7 * \sigma_{ef}})$	Vp todas las litologías
	$V_s = 3.7 - 4.94 * \phi - 1.57 * (V_{SH})^{0.5} + 0.361 * (\sigma_{ef} - 1 * e^{-16.7 * \sigma_{ef}})$	Vs todas las litologías
Krief (1990)	$V_s = \sqrt{\frac{V_p^2 - b}{a}}$	Todas las litologías
Williams (1990)	$V_s = 0.846 * V_p - 1.088$ [Km/s]	Areniscas saturadas
	$V_s = 0.784 * V_p - 0.893$ [Km/s]	Lutitas
Greenberg-Castagna (1992)	$V_s = 0.80416 * V_p - 0.85588$ [Km/s]	Areniscas
	$V_s = -0.05508 * V_p^2 + 1.01677 * V_p - 1.03049$ [Km/s]	Calizas
	$V_s = 0.58321 * V_p - 0.07775$ [Km/s]	Dolomías
	$V_s = 0.76969 * V_p - 0.86735$ [Km/s]	Lutitas
Mavko (1998)	$V_s = 0.754 * V_p - 0.657$ [Km/s]	% Clay < 25
	$V_s = 0.842 * V_p - 1.099$ [Km/s]	% Clay > 25
	$V_s = 0.853 * V_p - 1.137$ [Km/s]	$\phi < 15$
	$V_s = 0.756 * V_p - 0.662$ [Km/s]	$\phi > 15$
Lee (2006)	$V_p = \sqrt{\frac{K + \frac{4}{3}\mu}{\rho}}$	Vp prop. elásticas
	$V_s = \sqrt{\frac{\mu}{\rho}}$	Vs prop. elásticas

Tabla 1. Recopilación de las correlaciones para obtener la velocidad de corte de las formaciones V_s , (López-Aguirre, 2016).

Descripción de los parámetros elásticos y parámetros de resistencia

Por su parte, los parámetros elásticos consisten del Módulo de Young (E), relación de Poisson (ν), Módulo volumétrico (k), Módulo de corte (μ) y Parámetro de Lamé (λ). Pueden obtenerse mediante diferentes técnicas como las siguientes:

- Método autoconsistente, propuesto por Valdiviezo y Nicolás, (2014), en el que, a partir de valores iniciales de rocas y fluidos, mediante un proceso iterativo determina el valor de los parámetros elásticos del medio.
- Mediante métodos analíticos, con ecuaciones en función de la densidad volumétrica (ρ), velocidad compresional (V_p) y velocidad de corte (V_s). A continuación, se describe a mayor detalle esta metodología conjuntamente con la definición de las variables involucradas.
- Utilizando redes neuronales, como será planteado en el presente trabajo.

Los valores característicos de los parámetros elásticos son los que se muestran en la **Tabla 2**.

Mineral o Fluido	ρ Densidad Matriz [g/cc]	E Módulo Young [Gpa]	ν Poisson [Adim]	K Módulo de Bulto [GPa]	μ Módulo de Corte [GPa]	λ Parámetro de Lamé [GPa]
Cuarzo	2.65	95	0.07	37	44	8
Feldspatos	2.62	40	0.32	37.5	15	28
Plagioclasas	2.63	70	0.35	76	26	59
Calcita	2.71	84	0.32	77	32	56
Dolomita	2.87	117	0.3	95	45	65
Anhidrita	2.98	72	0.23	45	29	26
Siderita	3.96	135	0.32	124	51	90
Pirita	4.93	305	0.15	147	132	59
Arenisca	2.6	32-105	0.05	15-18	7 a 24	1 a 3
Caliza	2.72	97-280	0.33	37-71	9 a 26	18-53
Lutita	2.3-2.6	20-160	0.27	16-36	2 a 19	3 a 24
Agua de Formación	1.03	0	0.5	2.3	0	2.3
Hidrocarburos (40 API)	0.83	0	0.5	1.6	0	1.6

Tabla 2. Valores de módulos elásticos de referencia para diferentes materiales geológicos presentes en las rocas sedimentarias, (Agilegeoscience, 2011).

Adicionalmente existen relaciones entre parámetros elásticos, con las que se puede determinar cualquier parámetro elástico a partir de otros dos, **Figura 1**.

K	E	λ	ν	G	M
$\lambda + \frac{2G}{3}$	$G \frac{3\lambda + 2G}{\lambda + G}$	-	$\frac{\lambda}{2(\lambda + G)}$	-	$\lambda + 2G$
-	$9K \frac{K - \lambda}{3K - \lambda}$	-	$\frac{\lambda}{3K - \lambda}$	$3 \frac{K - \lambda}{2}$	$3K - 2\lambda$
-	$\frac{9K - G}{3K - G}$	$K - \frac{2G}{3}$	$\frac{3K - 2G}{2(3K + G)}$	-	$K + 4 \frac{G}{3}$
$\frac{\varepsilon G}{3(3G - E)}$	-	$G \frac{E - 2G}{3G - E}$	$\frac{E}{2G} - 1$	-	$G \frac{4G - E}{3G - E}$
-	-	$3K \frac{3K - E}{9K - E}$	$\frac{3K - E}{6K}$	$\frac{3KE}{9K - E}$	$3K \frac{3K + E}{9K - E}$
$\lambda \frac{1 + \nu}{3\nu}$	$\lambda \frac{(1 + \nu)(1 - \nu)}{\nu}$	-	-	$\lambda \frac{1 - 2\nu}{2\nu}$	$\lambda \frac{1 - \nu}{\nu}$
$G \frac{2(1 + \nu)}{3(1 - 2\nu)}$	$2G(1 + \nu)$	$G \frac{2\nu}{1 - 2\nu}$	-	-	$G \frac{2 - 2\nu}{1 - 2\nu}$
-	$3K(1 - 2\nu)$	$3K \frac{\nu}{1 + \nu}$	-	$3K \frac{1 - 2\nu}{2 + 2\nu}$	$3K \frac{1 - \nu}{1 + \nu}$
$\frac{E}{3(1 - 2\nu)}$	-	$\frac{E\nu}{(1 + \nu)(1 - 2\nu)}$	-	$\frac{E}{2 + 2\nu}$	$\frac{E(1 - \nu)}{(1 + \nu)(1 - 2\nu)}$

Figura 1. Relación entre los diferentes módulos elásticos para un material homogéneo e isotrópico, (Zoback, 2007).

Por su parte, los parámetros de resistencia se obtienen normalmente de pruebas de laboratorio para un punto en el subsuelo, también pueden obtenerse mediante las correlaciones presentadas para aproximarlos en intervalos extensos. Estos últimos son susceptibles de calibrarse a través de datos “duros” (valores obtenidos en el laboratorio), con los que se corroboran los comportamientos estimados con patrones reconocidos en pruebas. La representación gráfica de los parámetros de resistencia de la roca, están representados por el círculo de Mohr, en donde cada uno de ellos adquiere un sentido físico.

A continuación, se mencionan de manera breve, algunas correlaciones y ecuaciones utilizadas comúnmente para predecir los parámetros de resistencia de la roca, como el esfuerzo de compresión uniaxial (UCS), ángulo de fricción interna (ϕ), cohesión (S_o), coeficiente de fricción (μ) y esfuerzo de tensión (T_o). La discretización estos valores, resulta útil para generar las bases de datos para el entrenamiento de las redes neuronales.

Existen algunas correlaciones para aproximar la USC , en función de varios registros y para diferentes tipos de litologías, como las que se muestran en la **Tabla 3**.

Litología	Referencia	Correlación	Descripción	Observaciones
Lutitas	Horsrud (2001)	$111.68 * \left(\frac{V_p}{1000}\right)^{2.93}$	Para Lutitas del Cenozoico de alta porosidad	Probado en el Mar del Norte. UCS en [psi], Vp en [m/s]
	Chang-Zoback (2004)	$75.52 * \left(\frac{V_p}{1000}\right)^3$	Lutitas del Cenozoico del Golfo de México	Probado en el Golfo de México. UCS en [psi], Vp en [m/s]
	Horsrud (2001)	$423.8 * \phi^{-0.96}$	Para Lutitas del Cenozoico de alta porosidad	Probado en el Mar del Norte. UCS en [psi], Vp en [m/s]
Areniscas	Oyler (2009)	$468,000 * e^{-0.054DTCO}$	Para Areniscas de baja porosidad	Probado en el oeste de Virginia EUA. UCS en [psi], DTCO en [us/ft]
	Vernik (1993)	$36,830 * (1 - 2.7\phi)^2$	Para areniscas consolidadas	Presenta un limite de porosidad no mayor a 30%. UCS en [psi], Porosidad adimensional
Carbonatos	Miltzer-Stoll (1973)	$\left(\frac{7682}{DTCO}\right)^{1.82}$	Calizas compactas y masivas	UCS en [psi], DTCO en [us/ft]
	Chang-Zoback (2004)	$19,757.14 * e^{-4.8\phi}$	Calizas de baja porosidad	Presenta un limite de porosidad no mayor a 30%. UCS en [psi], Porosidad adimensional
	Amani (2013)	$82,789 * e^{-0.031DTCO}$	Calizas compactas y masivas	Probado en campo Ahwaz, Iran. UCS en [psi], DTCO en [us/ft]

Tabla 3. Correlaciones disponibles para predecir la USC a partir de datos de registros, (López-Aguirre, 2016).

Por su parte, el ángulo de fricción interna determina el incremento de la resistencia que presenta un paquete rocoso bajo condiciones de presión de confinamiento, el cual se define como el ángulo cuya tangente relaciona la fuerza que resiste una roca a deslizarse y la fuerza normal,

ambos actuando sobre un plano. Este parámetro es una propiedad de la roca indispensable para modelar el comportamiento de su resistencia a profundidad. La **Tabla 4**, muestra las correlaciones disponibles para estimular este parámetro, en función del tipo de roca.

Litología	Referencia	Correlación	Descripción	Observaciones
Lutitas	Fang Lal (1999)	$sen^{-1}\left(\frac{V_p - 1000}{V_p + 1000}\right)$	Para Lutitas del Cenozoico de alta porosidad	Φ , en [grados], Vp en [m/s]
Areniscas	Fang Vsh2 (1995)	$20.5 + 15 * (1 - V_{SH})$	Para Areniscas consolidadas	Φ , en [grados], Vsh en [adim]
Carbonatos	Bemer (2004)	$-89.3 * (\Phi) + 49$	Calizas compactas y masivas	Φ , en [grados], Por [adim]

Tabla 4. Correlaciones considerando distintas litologías para obtener el ángulo de fricción interna (ϕ), (López-Aguirre, 2016).

La cohesión se define como la fuerza de atracción que existe entre las partículas de una roca, y hace que se mantengan unidas entre sí. Las rocas dependiendo de su composición, profundidad y ambiente de depósito, así como los fluidos que contengan y la carga litostática que tengan sobre ellas, tienen un valor de cohesión dado. La cohesión también se

define como la ordenada al origen de la curva de tangente a los círculos de Mohr variando la presión de confinamiento. Este valor, conjuntamente con el ángulo de fricción interna, es importante para realizar el análisis de estabilidad del pozo, mediante el criterio de falla de Mohr- Coulomb.

Para obtener la magnitud de la cohesión en [psi], existe la ecuación siguiente en función de la velocidad compresional.

$$S_o = \frac{725*(V_P-1)}{\sqrt{V_P}} \quad (1)$$

Donde:

V_p , se expresa en [km/s]

Por su parte, la ecuación para resolver el valor del coeficiente de fricción interna es la siguiente.

$$\mu = \tan \Phi \quad (2)$$

El esfuerzo de tensión que puede presentar la roca, bajo condiciones de no confinamiento, se expresa con valor negativo y es igual al valor del esfuerzo principal mínimo (σ_3), en dichas condiciones. La expresión para determinar la magnitud de este parámetro es el siguiente.

$$T_o = \frac{UCS*(1-\sin \Phi)}{(1+\sin \Phi)} \quad (3)$$

La metodología que se propone en este trabajo consiste en obtener los parámetros elásticos E , ν , K , μ , λ , así como los parámetros de resistencia de la roca, calculados inicialmente mediante el uso de las correlaciones de manera mecánica a partir de las metodologías descritas en la primera parte en este trabajo. Los resultados obtenidos con correlaciones son utilizados como los marcos de desarrollo de redes neuronales cuyo entrenamiento emula dichos procesos, de manera simultánea al entrenamiento de la red se generan modelos capaces de intra y extrapolar la información a otras zonas (geográficas relacionadas con áreas de estudio) y en otros rangos (paramétricos con lo que se simulan escenarios diversos), para la construcción de un modelo robusto de geomecánica.

Redes neuronales

Las redes neuronales (RNs) es una técnica de modelado flexible que se fundamenta en la eficiencia de los procesos nerviosos biológicos (Bishop, 1996; Haykin, 1999). Las RNs son capaces de descubrir relaciones lineales y no lineales entre datos numéricos con fines de análisis y predicción de comportamientos complejos.

Las principales ventajas de las RNs son:

- i. Adaptación, ya que contrariamente a los métodos estadísticos tradicionales, las RNs no requieren hipótesis sobre la forma o distribución de los datos por analizar. Adquieren el conocimiento a través del entrenamiento o “experiencia” que “almacena”, como valores numéricos de los pesos de las conexiones neuronales;
- ii. Flexibilidad, las RNs tienen la capacidad para aprender y cambiar rápidamente en ambientes de alta dimensionalidad, no linealidad y definido con un gran número de datos y
- iii. La tolerancia a datos imperfectos (ausencia de datos o problemas en la calidad), ya que la información se distribuye.
- iv. En las conexiones neuronales lo que produce redundancia en el almacenamiento de la información y fortaleza ante imprecisiones o perturbaciones, (van Gerven, 2018).

En un sistema neuronal artificial se establece una estructura organizada en capas, cuya unidad básica es la neurona. Las capas constituyen a la red y las interconexiones entre las neuronas se llaman “pesos” (coeficientes numéricos en el funcional neuronal). La modificación iterativa de los pesos permite la adaptabilidad y representa la capacidad de predicción de las RNs, (Kemp et al., 1997).

En general las neuronas se suelen agrupar en unidades estructurales denominadas capas. Dentro de una misma capa las neuronas suelen ser del mismo tipo y el conjunto

de capas constituye una red neuronal. Se distinguen tres tipos de capas, **Figura 2**, (Kosko, 1992).

- **Capa de entrada:** compuesta por neuronas que reciben datos o señales procedentes del entorno.
- **Capa de salida:** aquella cuyas neuronas proporcionan la respuesta de la red neuronal.
- **Capa oculta:** aquella que no tiene una conexión directa con el entorno.

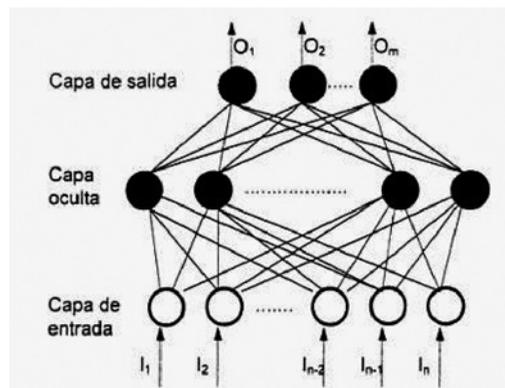


Figura 2. Capas de una red neuronal artificial, (Pino et al, 2001).

En las redes neuronales existen conexiones (sinapsis) asociadas a un peso sináptico y direccionales. Cuando la conexión se establece entre dos neuronas de una misma capa se habla de conexiones laterales o conexiones intra-capas. Por el contrario, si la conexión se establece entre neuronas de distintas capas se le denomina conexión inter-capas. Si la conexión se produce en el sentido inverso al de entrada-salida, la conexión se llama recurrente o retroalimentada. Las disposiciones de RNs en función del número de capas más representativas son las siguientes (Hertz et al., 1991):

1. Red neuronal monocapa. Es la RN más sencilla, ya que las neuronas de esta red funcionan como nodos de entrada y salida simultáneamente y no existen capas ocultas, **Figura 3**. Este tipo de redes es útil en tareas relacionadas con auto- asociación, es decir, regenera la información incompleta o distorsionada de patrones que se presentan a la red.

2. Red neuronal multicapa. En la red neuronal multicapa existe un conjunto de capas intermedias, (capas ocultas) entre la capa de entrada y la de salida, **Figura 4**. Estas redes se pueden a su vez clasificar atendiendo a la manera en que se conectan sus capas. Usualmente, las capas están ordenadas de acuerdo a cómo reciben la señal desde la entrada hasta la salida.

Ese tipo de conexiones se denominan conexiones de propagación hacia adelante feed forward, **Figura 5**. Por el contrario, existen redes en que algunas capas están también unidas desde la salida hasta la entrada en el orden inverso en que viajan las señales de información. Las conexiones de este tipo se llaman conexiones de retroalimentación o feedback donde una neurona puede estar conectada a las neuronas de otra capa y a ella misma.

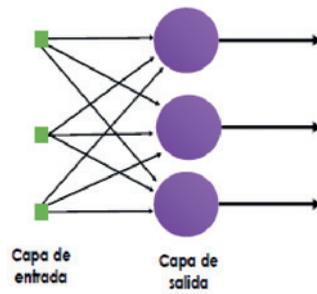


Figura 3. Representación de una red neuronal monocapa.

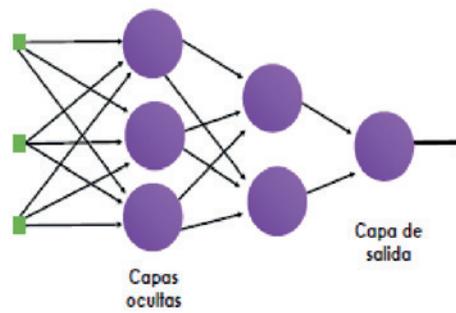


Figura 4. Representación de una red neuronal multicapa de propagación hacia adelante, (feedforward) o perceptrón.

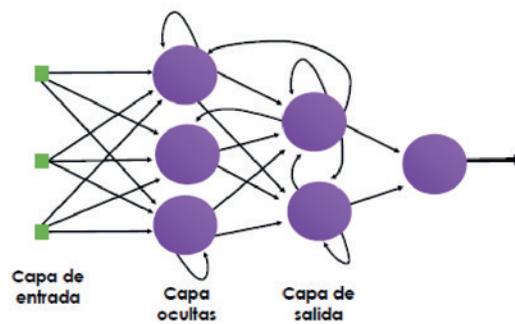


Figura 5. Representación de una red neuronal multicapa recurrente, (feedback).



El aprendizaje de una *RN* consiste en determinar un conjunto de pesos sinápticos que permita a la red realizar una tarea. Para que la red resulte operativa es necesario entrenarla. Antes de iniciar el entrenamiento se debe definir la condición de ajuste a una tarea específica (cuando se dice que la *RN* ha aprendido). Entre los criterios más comunes se encuentran, (Sigüenza et al, 1993).

- Se ha alcanzado una cota de error que se considere suficientemente pequeña.
- Se ha llegado a un número máximo de iteraciones.
- Se ha llegado a un punto de saturación en el que, por más que se entrene, ya no es posible reducir el error.

La fase de entrenamiento consiste en hacer que la red sea capaz de extraer, a partir de ejemplos, normas generales que le permitan en el futuro responder adecuadamente a patrones nunca antes vistos. Durante esta fase es imprescindible establecer una condición de paro óptima que minimice el error y evite un sobre-ajuste, es decir, que la red es incapaz de generalizar para casos nuevos. Existen dos métodos de aprendizaje: supervisado y no supervisado. La diferencia principal entre ambos estriba en la existencia o no de un operador o usuario, (supervisor) que controle el aprendizaje de la red.

Existen muchas técnicas de aprendizaje supervisado, la que se empleó en esta investigación es el algoritmo Quick Propagation (*QP*), que opera rápidamente debido a su sencillez, ya que el cálculo en cada conexión no es más que una multiplicación y una suma. De igual manera, para ajustar los pesos de la conexión también realiza las mismas operaciones. Esto significa que en total el tiempo en el que se ejecuta el algoritmo depende de la velocidad en que el procesador pueda realizar dos multiplicaciones y dos sumas, lo que implica muy poco trabajo para cada conexión.

QP se define como un algoritmo de aprendizaje supervisado que proporciona varias reglas metodológicas útiles para minimizar el tiempo requerido para encontrar un buen conjunto de pesos. Dichas reglas metodológicas regulan automáticamente el cálculo y detectan condiciones que aceleran el aprendizaje. Esta técnica evalúa la tendencia de las actualizaciones de peso a lo largo del tiempo para determinar cuándo se puede optimizar el cómputo. Para profundizar más en el tema y obtener una explicación más detallada el lector puede consultar, (Hassoun, 1995) y (Hertz et al., 1991).

Una vez obtenidos estos pesos, la red está lista para ser probada con patrones ajenos al entrenamiento. El objetivo de esta comprobación es observar el comportamiento de la red cuando las entradas son distintas a las que usaron en el entrenamiento. Al entrenar una red neuronal e intentar minimizar el error se corre el riesgo de sobre especialización (comportamiento óptimo con los ejemplos de entrenamiento, con casos distintos errores considerables). La minimización del error debe hacerse de manera equilibrada y muy cuidadosa, de tal forma que no origine una pérdida de generalización. Una vez que ésta resulte operativa, la arquitectura, neuronas, conexiones y pesos quedan fijos y la red está lista para funcionar. El conjunto de prueba debe ser i) significativo, (debe contener ejemplos pertenecientes a todas las clases establecidas) y ii) representativo, (debe guardar la relación existente entre los ejemplos del conjunto de entrenamiento), (Bishop, 1996).

García-Benítez (2009), analizó y utilizó redes neuronales, además de otros métodos de obtención con lo que llama cómputo suave (soft computing), para obtener la velocidad de corte mediante el cono de penetración para secuencias someras de roca. Con base en dicha investigación, se ha inspirado la extensión de la utilización de las *RNs* a la obtención de la V_s y elásticos, con aplicación en la industria petrolera.

Caso práctico en la obtención de la velocidad de corte y parámetros geomecánicos con redes neuronales

Los datos utilizados en este trabajo son principalmente curvas de registros geofísicos que han sido auditados para controlar su calidad. Se utilizaron siete pozos para el proceso de entrenamiento de la red que se suman a nueve pozos con los que se probaron y validaron las salidas, (parámetros) de la red neuronal.

Las variables de entrada, tanto para pozos de entrenamiento como para pozos de prueba, son inicialmente cinco y posteriormente se convierten en seis:

- A. Información de Profundidad (*TVD*)
- B. Registro de Rayos Gamma (*GR*)
- C. Registro de Tiempo de Tránsito (*DT*)
- D. Registro de Densidad de Bulto (*RHOB*)
- E. Registro de Velocidad Compresional (*VP*)

Con el conjunto anterior y la información de velocidad de corte (V_s), que se transforma de curva de salida a alimentación de entrada en cálculos subsecuentes, se obtiene información adicional para la estimación de varios parámetros geomecánicos, objetivos de este trabajo.

De manera general la metodología planteada se describe de la siguiente manera:

- ✓ Identificación de pozos y curvas de registros para el entrenamiento

- ✓ Identificación de pozos para obtención de parámetros geomecánicos
- ✓ Integración y carga de pseudopozos de entrenamiento y prueba
- ✓ Selección de algoritmos y condiciones de trabajo de la red neuronal
- ✓ Monitoreo de parámetros durante tiempo de cómputo
- ✓ Análisis de resultados y calibración con datos duros

La información empleada para generar las redes neuronales de los registros anteriormente mencionados, entre pozos de entrenamiento y pozos de prueba, consta de la cantidad de datos siguiente:

<i>Tipo de datos</i>	<i>Resolución vertical [m]</i>	<i>Líneas de datos (n)</i>
<i>Datos de entrenamiento: →</i>	<i>0.1524</i>	<i>52, 132</i>
<i>Datos de prueba: →</i>	<i>2.0000</i>	<i>6,547</i>

Como puede notarse, la cantidad de datos de prueba es aproximadamente el 10 % de los datos de entrenamiento, la cual se considera adecuada para controlar la evolución de los modelos y para asegurar que la validación sea correcta. No obstante, debe mencionarse que los datos de entrenamiento corresponden a la información de siete pozos con una resolución vertical alta, mientras que los datos de prueba corresponden con la información de nueve pozos con una resolución vertical de dos metros.

En la **Figura 6** se muestran las cuatro curvas de entrada de los siete pozos de entrenamiento, condensadas en un pseudopozo integrado, con la finalidad de obtener los parámetros geomecánicos con redes neuronales. Debe recordarse que la velocidad de corte (V_s), inicialmente es un resultado o aproximación de una Red Neuronal (predicción), es decir, primero se estimaron las curvas de v_s para los nueve pozos de prueba y posteriormente se integraron como curvas de entrada.

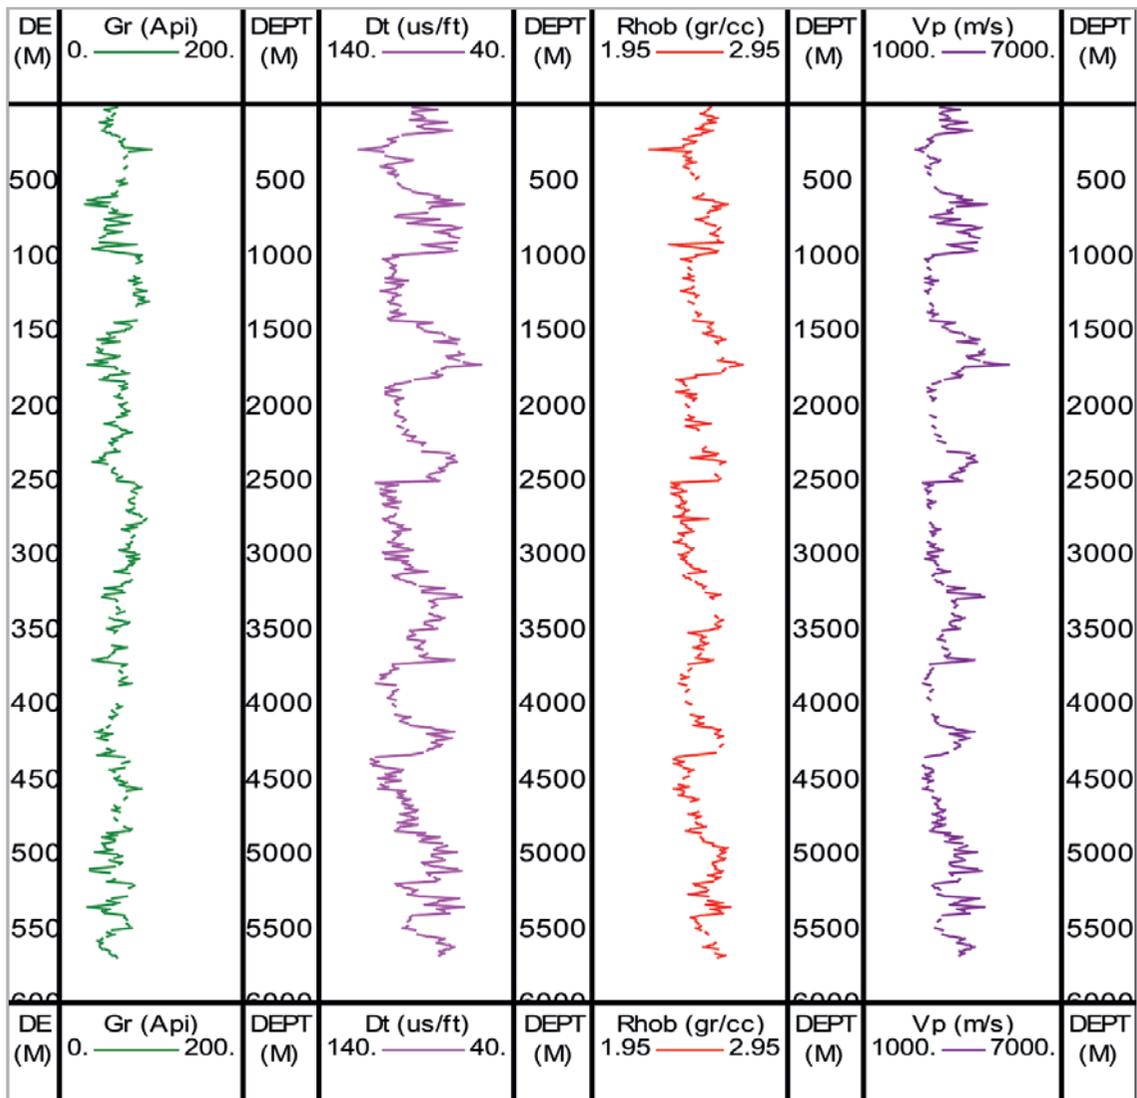


Figura 6. Curvas de datos de pozo de entrada para las redes neuronales.

Los resultados para la V_s obtenida con redes neuronales son los que se aprecian en la **Figura 7**. Los resultados obtenidos de redes fueron puestos en contexto con curvas medidas (carril dos), registro *DSI*, afectados por 0.9 y por 1.1 (carril tres), para verificar el más menos 10 % de error permitido (carril cuatro).

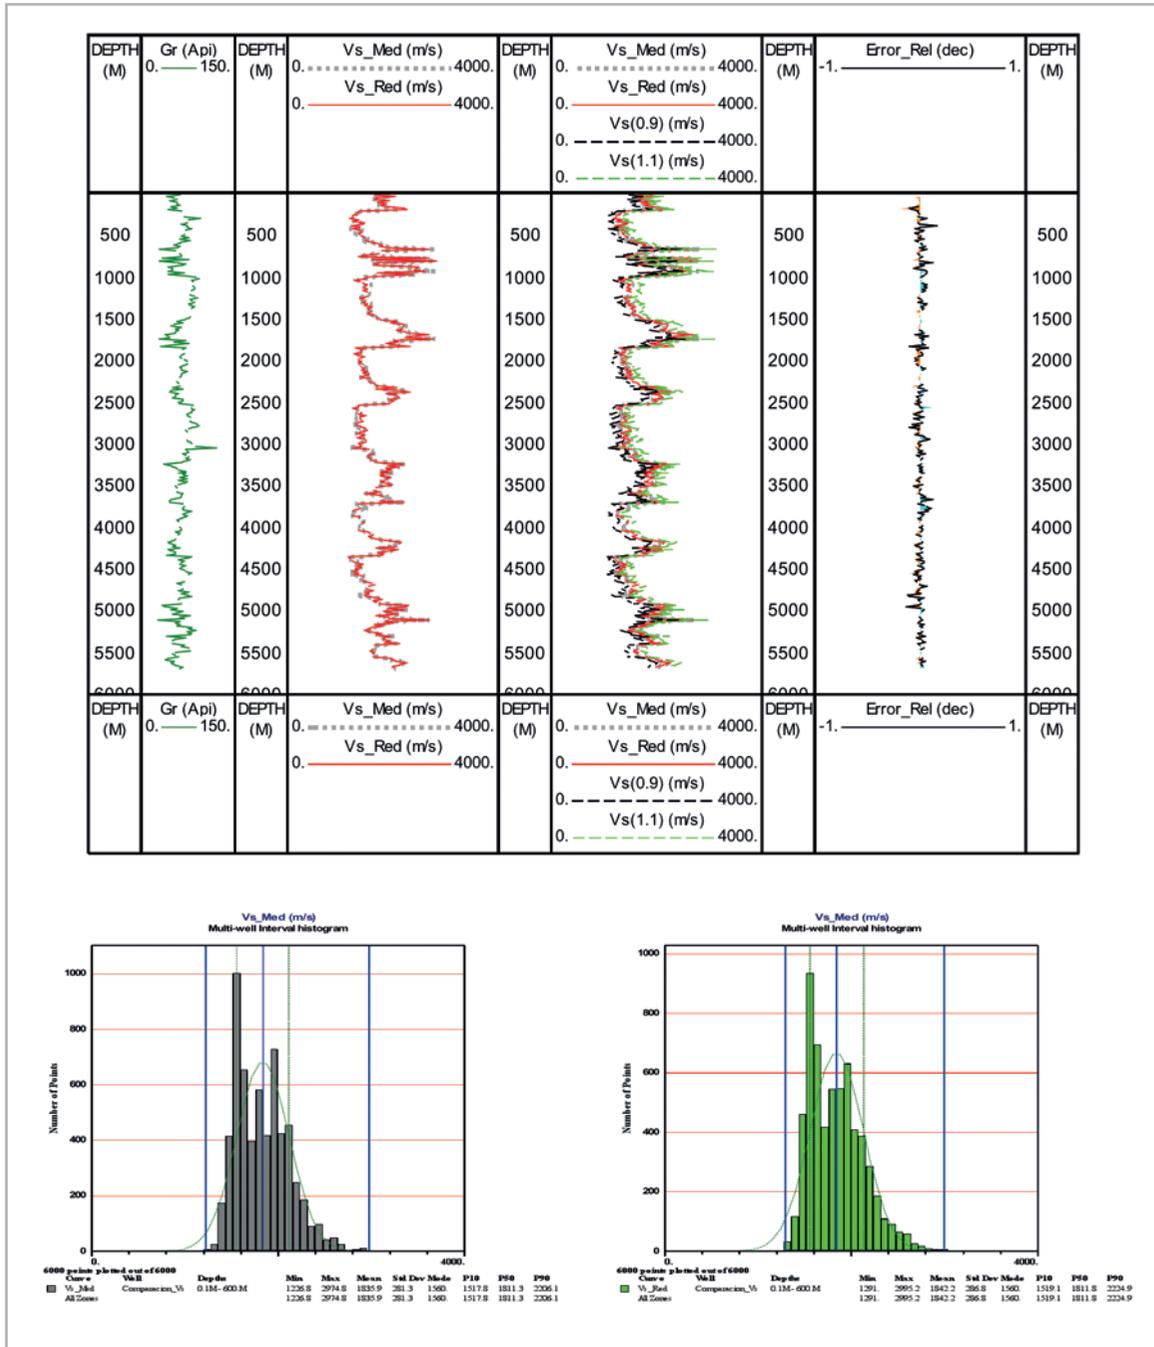


Figura 7. Resultados obtenidos con redes neuronales para V_s .

Con la finalidad de confirmar la efectividad de los resultados obtenidos para V_s , se efectuó un análisis recursivo con V_p y $RHOB$, corriendo la red neuronal con el mínimo de información de entrada, es decir, se plantearon dos escenarios, uno de ellos para cuando únicamente se cuenta con $RHOB$, se obtuvieron V_p y V_s . Así como, un segundo escenario para cuando se cuenta únicamente con V_p , se obtuvieron V_s y $RHOB$.

Los resultados obtenidos para estos ensayos fueron alentadores, obteniendo una alta correlación entre las velocidades medidas y las obtenidas con redes neuronales (mayor al 95%) que se muestra en los carriles tres y cuatro la **Figura 8**, en tanto que la correlación entre la densidad medida y la obtenida con redes fue del 89% observándose una mayor resolución en los datos medidos que los que predice la red neuronal, como se muestra en el carril tres de la **Figura 9**.

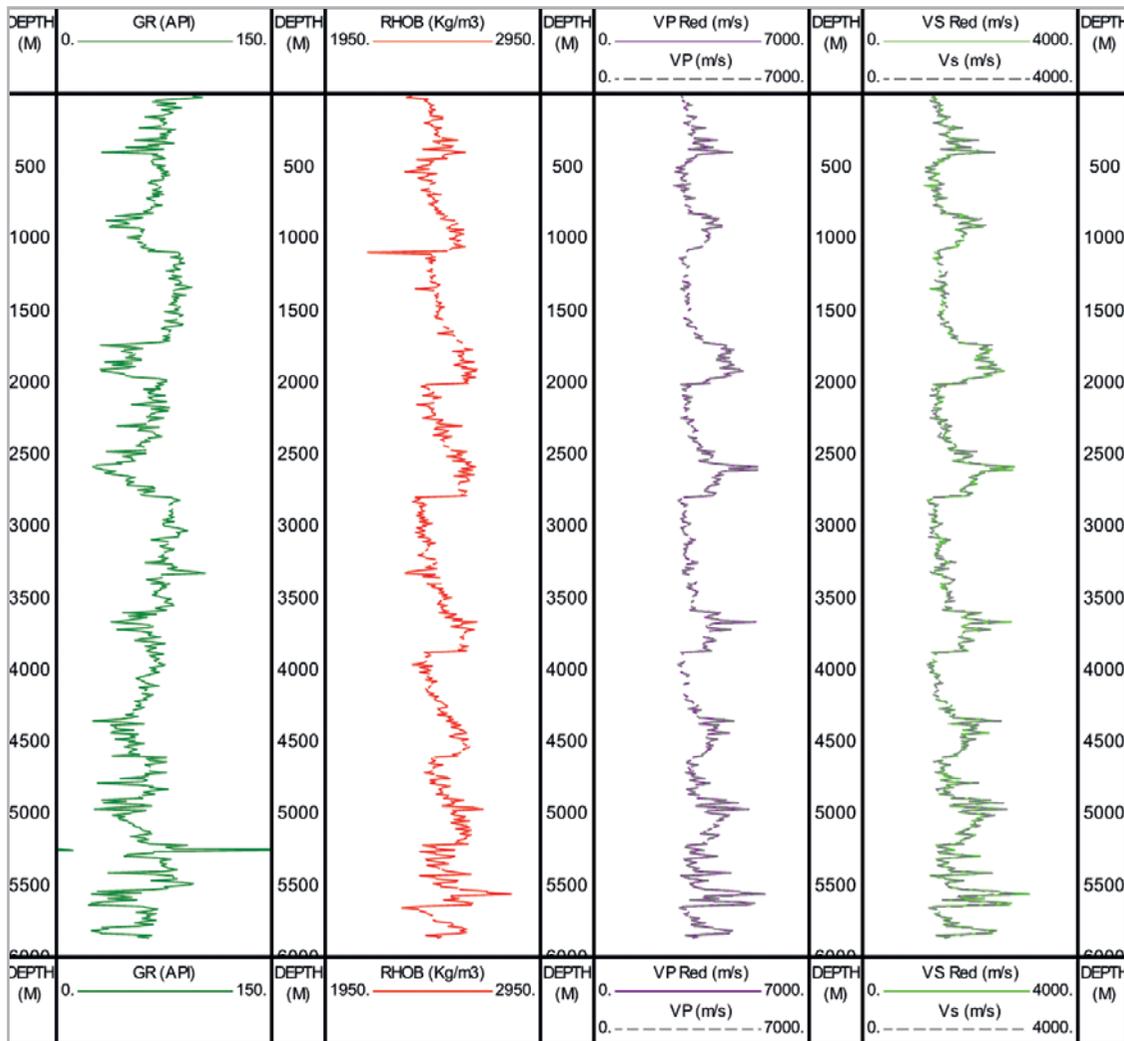


Figura 8. Resultados para V_p y V_s , a partir de $RHOB$.

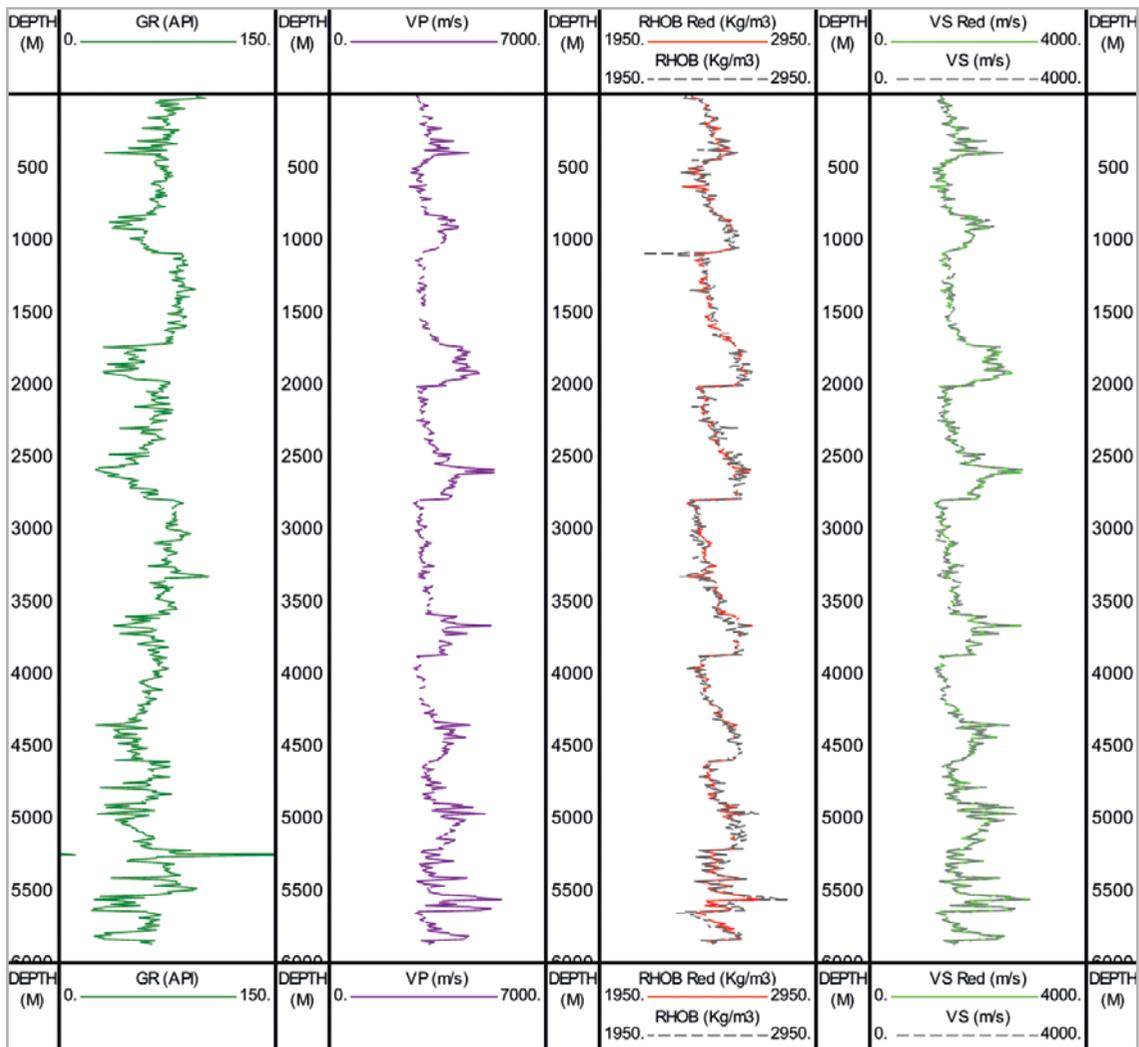


Figura 9. Resultados para para $RHOB$ y V_s , a partir de V_p .

En términos generales se observa que las aproximaciones obtenidas con redes neuronales para las velocidades fueron positivas, por otro lado, para la obtención de la densidad volumétrica, aunque el resultado fue también positivo (correlación del 89%), se requiere profundizar el análisis combinando otras metodologías convencionales y de inteligencia artificial.

Con los resultados obtenidos en los pozos de entrenamiento, **Figura 10**, se concluyó sobre la coherencia de operación de la red neuronal. Al analizar las velocidades de corte calculadas en los pozos de prueba (en los que no se cuenta con datos del registro *DSI*, **Figura 11**, lo que significó un camino alternativo para robustecer el conjunto de informaciones disponibles para el análisis de geomecánica.

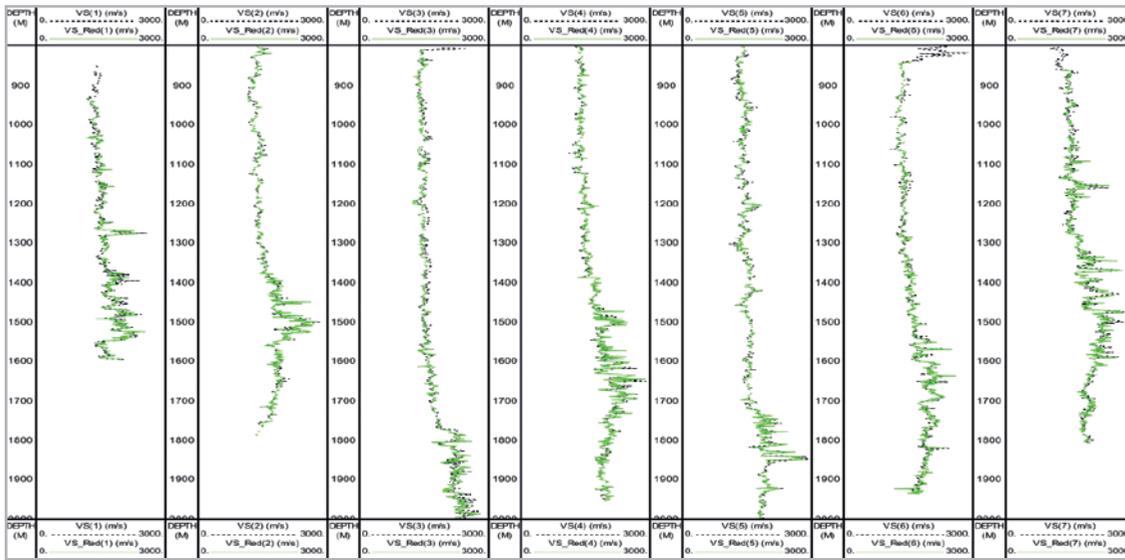


Figura 10. Resultados obtenidos con redes neuronales para V_s , para los pozos de entrenamiento.

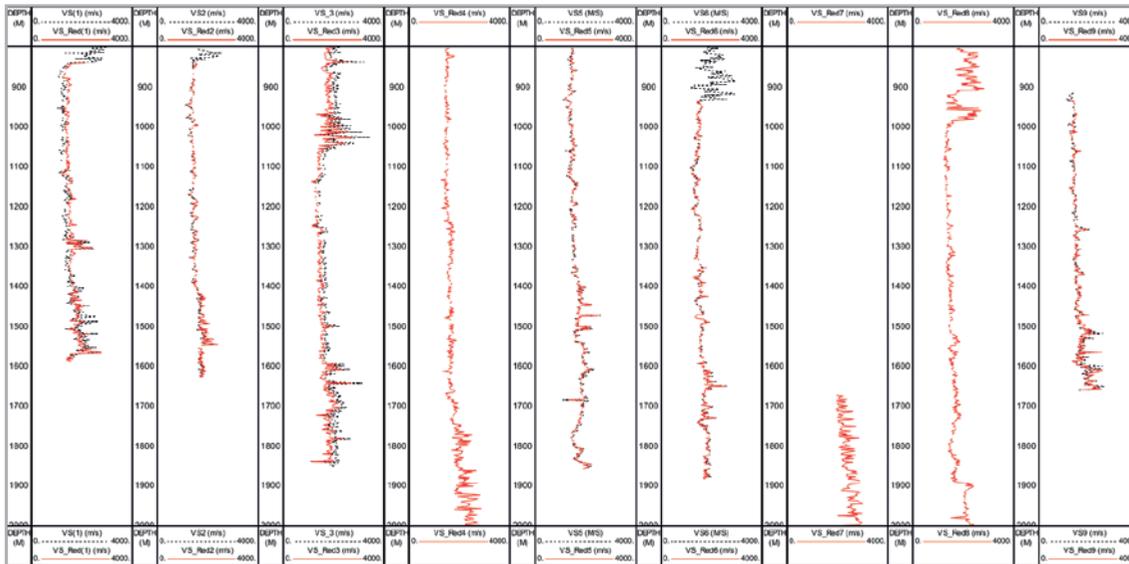


Figura 11. Resultados obtenidos con redes neuronales para V_s , para los pozos de prueba.

Los resultados obtenidos para los parámetros elásticos de prueba, calculados con topologías neuronales, son satisfactorios, además de que se requieren tiempos muy reducidos de cómputo (número de iteraciones < 1000), **Figura 12**.

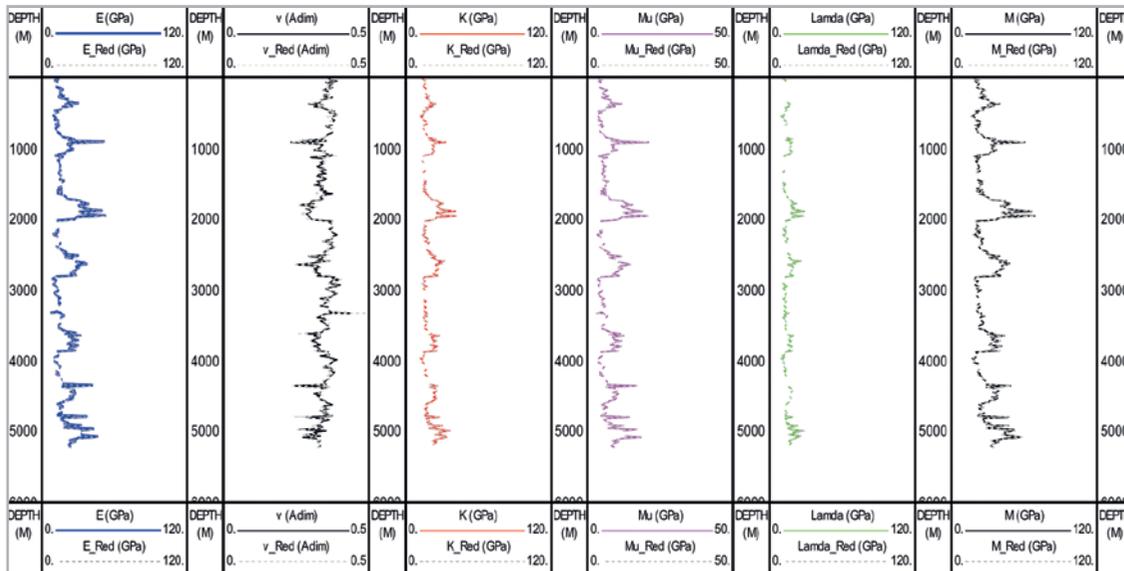


Figura 12. Resultados obtenidos con redes neuronales para para los pozos de prueba.

Los resultados del modelado de parámetros de resistencia de la roca obtenidos de redes neuronales (*UCS*, ángulo de fricción interna, coeficiente de fricción, cohesión y tensión), para los siete pozos de entrenamiento, muestran una buena correlación con los calculados. En la **Figura 13**, se muestran estas aproximaciones.

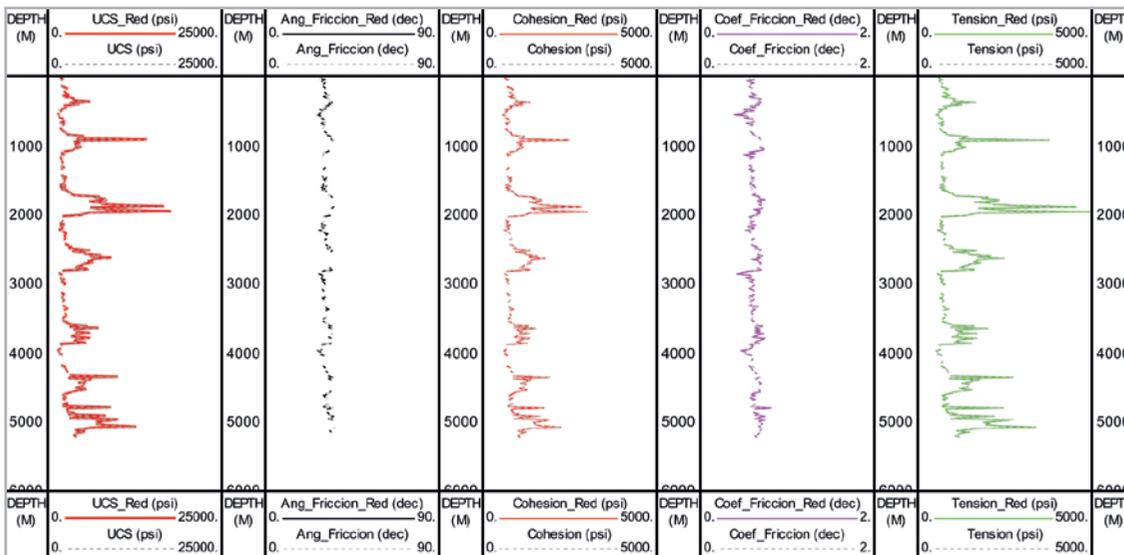


Figura 13. Resultados obtenidos con redes neuronales para *UCS*, ϕ , S_o , μ , T_o ; para los pozos de entrenamiento.

Por su parte, los resultados para los pozos de prueba muestran buena correlación con datos calculados, (con otros métodos). Dada la independencia entre los resultados se considera que la red neuronal es eficiente, **Figura 14**.

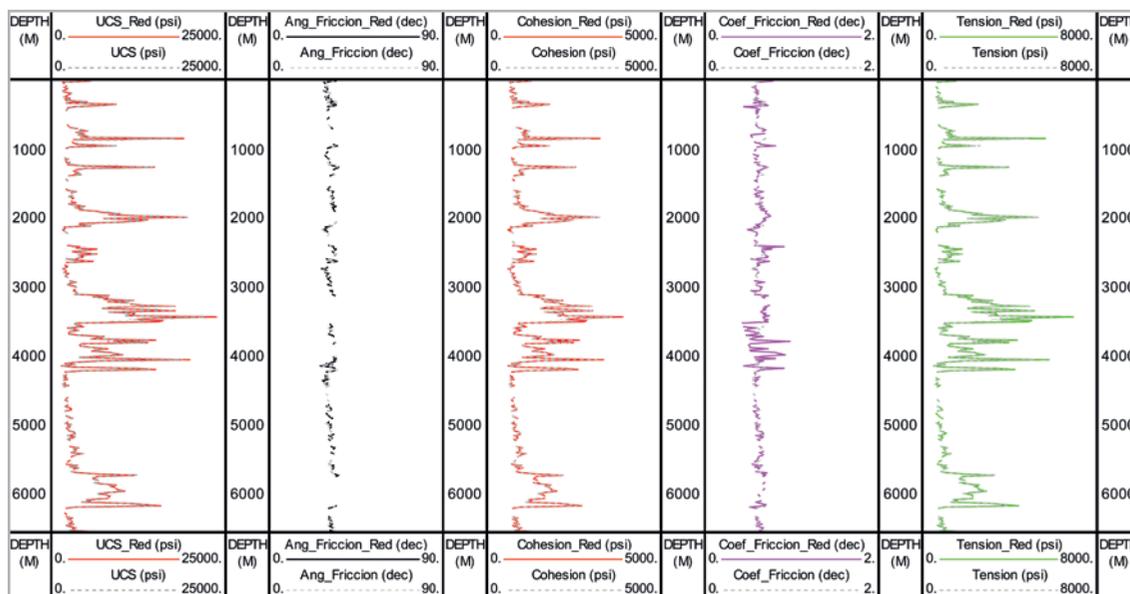


Figura 14. Resultados obtenidos con redes neuronales para UCS , ϕ , S_o , μ , T_o ; para los pozos de prueba.

Conclusiones y recomendaciones

La metodología empleada a partir del entrenamiento de las redes neuronales para determinar la velocidad de corte y parámetros elásticos fue satisfactoria, puede extenderse a la estimación de otros parámetros de interés petrolero.

Se obtuvieron curvas de velocidad de corte y parámetros elásticos, con un promedio de 96 % de exactitud contra datos medidos en campo, para los casos de entrenamiento, mientras que, para los datos de prueba, los resultados también presentan una correlación bastante aceptable con respecto a los datos calculados.

La exactitud obtenida con redes neuronales, no se había obtenido con ninguna correlación disponible en la literatura para estos parámetros. Adicionalmente, se visualizó como ventaja práctica en el uso de esta técnica que, mediante el entrenamiento adecuado de los datos de un número reducido de pozos, puede extrapolarse a otros pozos y áreas de dimensiones grandes con características similares.

Se pusieron en práctica las características descritas en la literatura para definir a las redes neuronales (adaptación, flexibilidad, la tolerancia a datos imperfectos), al someterlas

a diferentes condiciones de cálculo, de diferentes conjuntos de variables como se ha mostrado en este trabajo.

Con los resultados obtenidos es posible integrar un modelo de geomecánica para cada pozo, o pseudopozo, en diferentes áreas de estudios a partir de información limitada.

A partir del punto anterior, se pueden construir modelos tridimensionales (3D), que permitan definir en cualquier punto del espacio valores de elasticidad, resistencia, esfuerzos, etc; de gran utilidad para contribuir a la identificación de zonas con las mejores características para la explotación de hidrocarburos.

Referencias bibliográficas

1. Aadnoy, B. S. y Looyeh, R., eds. 2010. *Petroleum Rock Mechanics: Drilling Operations and Well Design*, second edition. Cambridge, Massachusetts: Gulf Professional Publishing.
2. Bianco, E. 2011. Rock Physics Cheatsheet. Blog: Views and News About Geoscience and Technology, 7 de marzo 2011. <http://www.agilegeoscience.com/>

- <blog/2011/3/7/rock-physics-cheatsheet.html> (fecha de acceso: 17 de febrero de 2019).
3. Bishop, C. M. 1996. *Neural Network for Pattern Recognition*. Oxford: Clarendon Press.
 4. Casacuberta Nolla, F. 1998. Redes Neuronales Artificiales. *Novática: Revista de la Asociación de Técnicos de Informática* 131: 15-17.
 5. García Benítez, S. R. 2009. *Cómputo Aproximado en la Solución de Problemas Geosísmicos*. Tesis de doctorado, Universidad Nacional Autónoma de México, Programa de Maestría y Doctorado en Ingeniería, Ingeniería Civil, México, D.F.
 6. Greenberg, M. L. y Castagna J. P. 1992. Shear-wave Velocity Estimation in Porous Rocks: Theoretical Formulation, Preliminary Verification and Application. *Geophysical Prospecting* **40** (2): 195–209. <https://doi.org/10.1111/j.1365-2478.1992.tb00371.x>.
 7. Hassoun, M. H. 1995. *Fundamentals of Artificial Neural Networks*. Cambridge, Massachusetts: The MIT Press.
 8. Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*, second edition. New York: Prentice Hall.
 9. Hertz, J., Krogh, A. y Palmer, R. G. 1991. *Introduction to the Theory of Neural Computation*. Redwood, City, California: Addison-Wesley Publishing Company.
 10. Hetch-Nielsen, R. 1988. Neurocomputing: Picking the Human Brain. *IEEE Spectrum* **25** (3): 36-41. <https://doi.org/10.1109/6.4520>.
 11. Kemp, R., McAulay, C. y Palcic, B. 1997. Opening the Black Box: The Relationship Between Neural Networks and Linear Discriminant Functions. *Analytical Cellular Pathology* **14**: Article ID 646081. <https://doi.org/10.1155/1997/646081>.
 12. Kosko, B. 1992. *Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*. Englewood Cliffs, New Jersey: Prentice-Hall.
 13. López-Aguirre, D. 2016. *Geomecánica para Formaciones Siliciclásticas, Mediante Análisis de Sistemas Petroleros y Compresibilidades*. Tesis de maestría, Universidad Nacional Autónoma de México, Programa de Maestría y Doctorado en Ingeniería, EERN, Ciudad de México, 2016.
 14. Mavko, G., Mukerji, T. y Dvorkin, J. 2003. *The Rock Physics Handbook: Tools for Seismic Analysis in Porous Media*, second edition. Cambridge, UK: Cambridge.
 15. Nicolás López, R. y Valdiviezo Mijangos, O. C. 2015. Rock Physics Templates for Integrated Analysis of Shales Considering their Mineralogy, Organic Matter and Pore Fluids. *Journal of Petroleum Science and Engineering* **137** (January): 33-41. <https://doi.org/10.1016/j.petrol.2015.11.009>.
 16. Pino Díez, R., Gómez Gómez, A. y Abajo Martínez, N. de. 2001. *Introducción a la Inteligencia Artificial: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva*. Oviedo, España: Universidad de Oviedo, Servicios de Publicaciones.
 17. Sigüenza, J., López, V. y Dorronsoro, J. 1993. Redes Neuronales, de la Investigación Básica a las Aplicaciones Industriales. *Chip* (abril): 66.
 18. Valdiviezo Mijangos, O. C. y Nicolás López, R. 2014. Dynamic Characterization of Shale Systems by Dispersion and Attenuation of P- and S-Waves Considering their Mineral Composition and Rock Maturity. *Journal of Petroleum Science and Engineering* **122** (October): 420-427. <https://doi.org/10.1016/j.petrol.2014.07.041>.
 19. van Gerven, M. y Bothe, S., eds. 2018. *Artificial Neural Networks as Models of Neural Information Processing*. Lausanne: Frontiers in Computational Neuroscience. <https://doi.org/10.3389/978-2-88945-401-3>.
 20. Zoback, M. D. 2007. *Reservoir Geomechanics*. Cambridge, UK: Cambridge University Press.

Semblanza de los autores

Daniel López Aguirre

Candidato a Doctor en Ingeniería Petrolera, Posgrado de Ingeniería, UNAM. Maestro en Ingeniería de Exploración y Explotación de Recursos Naturales Posgrado de Ingeniería, UNAM, con especialidad en perforación y geomecánica. Licenciatura como Ing. Petrolero y también Ing. Geólogo, egresado de la Facultad de Ingeniería, UNAM.

Profesionalmente se ha desempeñado como asesor de ingeniería de perforación y geomecánica, en instituciones públicas y privadas. Ingeniero de diseño de perforación y terminación de pozos en Petróleos Mexicanos. Profesor de ingeniería petrolera en la Facultad de Ingeniería, UNAM.

Silvia Raquel García Benítez

Doctora en Ingeniería Geotécnica, egresada del Posgrado de Ingeniería, Universidad Nacional Autónoma de México desde el 2009. Actualmente se desempeña como investigadora del Instituto de Ingeniería, UNAM, desarrollando proyectos relacionados con inteligencia artificial aplicada a problemas de la industria.

Rubén Nicolás López

Doctor en Ingeniería Petrolera y Gas Natural en la Opción de Perforación de pozos por la Universidad Nacional Autónoma de México desde el 2006. Actualmente en el Instituto Mexicano del Petróleo, es Tecnólogo para la explotación y desarrollo de campos y Catedrático del posgrado en el departamento de ingeniería petrolera en DEPMI - UNAM. Miembro del Sistema Nacional de Investigadores del Conacyt.