

Desarrollo de un modelo para la integración de registros de pozo con información de tomografía para la estimación de propiedades petrofísicas por medio de un modelo de redes neuronales

Oscar Guillermo Domínguez López

Trabajo de Grado para optar al título de Ingeniero de Petróleos

Director

Andrés Felipe Ortiz Meneses

M.Sc. en Ingeniería de Hidrocarburos

Universidad Industrial de Santander

Facultad de Ingenierías Físicoquímicas

Escuela de Ingeniería de Petróleos

Bucaramanga

2023

Dedicatoria

A mis padres Oscar Luis y Leida Linet, merecedores de respeto y admiración por su gran esfuerzo en la formación y educación de sus hijos. Gracias por su confianza y apoyo incondicional.

A mis hermanos Cielo Melissa y Juan Carlos, cada logro alcanzado también es suyo porque han sido parte fundamental en este proceso de aprendizaje profesional y personal.

A mis abuelos Oscar Augusto y Cielo Margarita, me alegra mucho poder compartir finalmente este logro con ustedes. Los quiero.

A mis abuelos Guillermo y Carmelina, a quienes con todo el corazón anhelo volver a ver y decirles lo agradecido que estoy por el corto tiempo que pude disfrutar con ellos.

A familiares y amigos que me ayudaron a confiar nuevamente en Dios y en mis capacidades para alcanzar las metas propuestas.

Oscar Guillermo Domínguez López

Agradecimientos

A Dios, por su guía y fidelidad en este largo camino y por darme la fortaleza que necesitaba en los momentos más difíciles.

A la Universidad Industrial de Santander por su formación integral de excelente calidad.

A la Escuela de Ingeniería de Petróleos y su planta docente que ha demostrado ser fuente de conocimiento y desarrollo tecnológico, profesional y personal.

A los integrantes del GIT por su valiosa contribución en la investigación y desarrollo de nuevas tecnologías aplicables en las áreas más importantes de la industria.

Al profesor Juan Badillo y al ingeniero Andrés Ortiz, por su valioso apoyo, disposición y confianza durante todo el proceso para el desarrollo del proyecto.

Al ingeniero Sr de Producción Edwin Triana, quien me permitió adquirir la experiencia profesional y conocer de cerca la mayoría de las operaciones Oil & Gas.

A todos, muchas gracias.

Tabla de Contenido

	Pág.
Introducción	15
2. Objetivos	16
2.1 Objetivo General	16
2.2 Objetivos Específicos.....	16
3. Marco Referencial.....	17
3.1 Escaneo con Energía Dual de Tomografía Computarizada	17
3.1.1 Principio Físico del Escaneo con Energía Dual	17
3.1.2 El Escáner de Tomografía Computarizada	20
3.2 Relaciones Teóricas entre Tomografía, Registros y las Propiedades Petrofísicas Básicas	21
3.3 Aplicación de los Modelos de Redes Neuronales.....	28
3.3.1 La Neurona Artificial.....	33
3.3.2 Perceptrones Multicapa.....	34
3.4 Modelos de Redes Neuronales usados para estimar Propiedades Petrofísicas a partir de Tomografía y a partir de Registros	36
4. Reporte de la información recolectada de Registros y Tomografía.....	38
5. Desarrollo de los Modelos de Estimación de Propiedades Petrofísicas Básicas a partir de Registros e Integrando Información de Tomografía	40
5.1 Modelos de Predicción de Porosidad	41
5.1.1 Datasets de Entrenamiento.....	43
5.1.2 Metodología aplicada en el Modelo de Predicción de Porosidad a partir de Registros.....	44
5.1.3 Metodología aplicada en el Modelo de Integración de Registros con Tomografía	48

5.2 Modelos de Predicción de Permeabilidad.....	55
5.2.1 Datasets de Entrenamiento.....	55
5.2.2 Metodología aplicada en el Modelo de Predicción de Permeabilidad a partir de Registros	57
5.2.3 Metodología aplicada en el Modelo de Integración de Registros con Tomografía	59
6. Análisis de Resultados	63
6.1 Modelos de Predicción de Porosidad.....	65
6.2 Modelos de Predicción de Permeabilidad.....	71
7. Conclusiones	77
8. Recomendaciones	78
Referencias Bibliográficas.....	79
Apéndices	82

Lista de Tablas

	Pág.
Tabla 1 Resumen de estimaciones de porosidad a partir de registros.....	27
Tabla 2 Resumen de estimaciones de permeabilidad (mD) a partir de registros.....	28
Tabla 3 Información recolectada de registros, tomografía y datos petrofísicos	38
Tabla 4 Topología de la red neuronal para entrenar el modelo de predicción de porosidad a partir de registros	45
Tabla 5 Parámetros de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros en tres diferentes corridas.....	46
Tabla 6 Topología de la red neuronal para entrenar el modelo de predicción de porosidad a partir de registros con tomografía.....	49
Tabla 7 Parámetros de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros con tomografía en siete diferentes corridas.....	50
Tabla 8 Topología de la red neuronal para entrenar el modelo de predicción de permeabilidad a partir de registros	57
Tabla 9 Parámetros de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros en cuatro diferentes corridas	58
Tabla 10 Topología de la red neuronal para entrenar el modelo de predicción de permeabilidad a partir de registros con tomografía.....	60
Tabla 11 Parámetros de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros con tomografía en siete diferentes corridas	60

Tabla 12 Resumen del set de datos del Pozo-1 para la evaluación de los modelos de predicción integrados con tomografía.....	63
Tabla 13 Resumen del set de datos del Pozo-2 para la evaluación de los modelos de predicción integrados con tomografía.....	64
Tabla 14 Resumen del set de datos del Pozo-3 para la evaluación de los modelos de predicción integrados con tomografía.....	64

Lista de Figuras

	Pág.
Figura 1 Configuración de un Escáner de Tomografía Computarizada	21
Figura 2 Aprendizaje supervisado	31
Figura 3 Aprendizaje no supervisado	32
Figura 4 Aplicaciones de los esquemas de aprendizaje para un modelo de aprendizaje automático	32
Figura 5 Esquema de una unidad neuronal artificial típica	33
Figura 6 Arquitectura del perceptrón multicapa	34
Figura 7 Parámetros para la evaluación de modelos por over-fitting o sobreajuste de datos.....	41
Figura 8 Flujo de trabajo para el desarrollo y evaluación de modelos de aprendizaje automático en Matlab	42
Figura 9 Flujo de trabajo aplicado para el desarrollo y evaluación de los modelos de aprendizaje automático en Matlab.....	42
Figura 10 Gráfico de rendimiento (performance plot) del entrenamiento del modelo de predicción de porosidad a partir de registros durante la corrida #2.....	47
Figura 11 Gráficos de regresión (regression plots) del entrenamiento del modelo de predicción de porosidad a partir de registros durante la corrida #2.....	48
Figura 12 Gráfico de rendimiento del entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía durante la corrida #7.....	51
Figura 13 Gráficos de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía durante la corrida #7	51

Figura 14 Distribución de la cantidad de datos en la interpolación para la integración de registros con tomografía	53
Figura 15 Gráfico de validación del registro GR aplicando el método de interpolación	54
Figura 16 Gráfico de rendimiento del entrenamiento del modelo de predicción de permeabilidad a partir de registros durante la corrida #4	58
Figura 17 Gráficos de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros durante la corrida #4	59
Figura 18 Gráfico de rendimiento del entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía durante la corrida #7	61
Figura 19 Gráficos de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía durante la corrida #7.....	61
Figura 20 Gráficos de regresión del modelo de predicción de porosidad a partir de registros evaluado sobre los Pozos 1 y 2	65
Figura 21 Gráficos de regresión del modelo de predicción de porosidad a partir de registros integrado con tomografía evaluado sobre los Pozos 1 y 2.....	66
Figura 22 Validación de los modelos de predicción de porosidad con dataset del Pozo-1	67
Figura 23 Validación de los modelos de predicción de porosidad con dataset del Pozo-2	69
Figura 24 Validación de los modelos de predicción de porosidad con dataset del Pozo-3	70
Figura 25 Gráficos de regresión del modelo de predicción de permeabilidad a partir de registros evaluado sobre los Pozos 1 y 2	71
Figura 26 Gráficos de regresión del modelo de predicción de permeabilidad a partir de registros integrado con tomografía evaluado sobre los Pozos 1 y 2.....	72
Figura 27 Validación de los modelos de predicción de permeabilidad con dataset del Pozo-1 .	73

Figura 28 Validación de los modelos de predicción de permeabilidad con dataset del Pozo-2. 75

Figura 29 Validación de los modelos de predicción de permeabilidad con dataset del Pozo-3. 76

Lista de Apéndices

	Pág.
Apéndice A. Dataset Pozo-3 para el entrenamiento del modelo de predicción de porosidad a partir de registros	82
Apéndice B. Dataset Pozo-3 para el entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía.....	86
Apéndice C. Dataset Pozo-3 para el entrenamiento del modelo de predicción de permeabilidad a partir de registros	90
Apéndice D. Dataset Pozo-3 para el entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía.....	95
Apéndice E. Script compilado en Matlab del modelo entrenado para la predicción de porosidad a partir de registros	99
Apéndice F. Script compilado en Matlab del modelo entrenado para la predicción de porosidad a partir de registros con tomografía.....	99
Apéndice G. Script compilado en Matlab del modelo entrenado para la predicción de permeabilidad a partir de registros.....	99
Apéndice H. Script compilado en Matlab del modelo entrenado para la predicción de permeabilidad a partir de registros con tomografía	99
Apéndice I. Script del modelo de integración de datos de registros con tomografía para la predicción de porosidad	100
Apéndice J. Script del modelo de integración de datos de registros con tomografía para la predicción de permeabilidad	101

Apéndice K. Modelo interactivo para la predicción de porosidad integrando datos de registros con tomografía.....	102
Apéndice L. Modelo interactivo para la predicción de permeabilidad integrando datos de registros con tomografía	105

Resumen

Título: Desarrollo de un modelo para la integración de registros de pozo con información de tomografía para la estimación de propiedades petrofísicas por medio de un modelo de redes neuronales*

Autor: Oscar Guillermo Domínguez López**

Palabras Clave: Registros de pozo, Tomografía computarizada, Propiedades petrofísicas, Redes neuronales artificiales, Aprendizaje automático.

Descripción: Este proyecto presenta un método que integra datos de registros de pozo con información de tomografía aplicando modelos de redes neuronales para predecir propiedades petrofísicas básicas. En principio, se recolectó la información de registros, tomografía y de propiedades petrofísicas de tres pozos de estudio y se establecieron sus relaciones teóricas a partir de la literatura. Primero, se diseñaron los modelos de predicción usando sólo datos de registros. Para este y los demás modelos se seleccionó un set de datos para entrenar redes neuronales con la herramienta *Machine Learning* de Matlab. Luego, a estos sets de entrenamiento se añadió la información de tomografía y se compararon los resultados. Los modelos de integración mostraron un mejor ajuste comparados con los modelos alimentados sólo con registros. Para validar el rendimiento de los modelos se evaluaron gráficos de regresión en los que se comparan los valores estimados con los datos de laboratorio recolectados de cada pozo, y adicionalmente se probaron los modelos de integración usando un set de validación que contiene los registros y tomografía de varias secciones completas de 3 ft escaneadas sobre muestras de núcleos de cada pozo. Los modelos de integración que se diseñaron permiten hacer predicciones de porosidad y permeabilidad bastante cercanas a los valores reales y con una resolución equivalente a la información que se obtiene al escanear muestras usando tomografía computarizada.

* Trabajo de Grado

** Facultad de Ingenierías Físicoquímicas. Escuela de Ingeniería de Petróleos. Director: Andrés Felipe Ortiz Meneses. M.Sc. en Ingeniería de Hidrocarburos.

Abstract

Title: Development of a model for the integration of well logs with tomography information for the estimation of petrophysical properties through a model of neural networks*

Author: Oscar Guillermo Domínguez López**

Key Words: Well logs, Computed tomography, Petrophysical properties, Artificial neural networks, Machine learning.

Description: This work presents a method that integrates well log data with tomography information by applying neural network models to predict basic petrophysical properties. In principle, log, tomography and petrophysical properties information from three study wells was collected and their theoretical relationships were established from the literature. First, prediction models were designed using only logs data. For this and the other models, a data set was selected to train neural networks with the Matlab *Machine Learning* toolbox. Then, the CT information was added to these training sets and the results were compared. The integration models showed a better fit compared to the models trained only with logs. To validate the performance of the models, regression plots were evaluated in which the estimated values are compared with the laboratory data collected from each well, and additionally the integration models were tested using a validation set that contains the logs and tomography of several full 3 ft sections scanned over core samples from each well. The integration models that were designed here allow predictions of porosity and permeability to be made quite close to the real values and with a resolution equivalent to the information obtained by scanning samples using computed tomography.

* Degree Work

** Faculty of Physicochemical Engineering, School of Petroleum Engineering, Director: Andrés Felipe Ortiz Meneses. M.Sc. in Hydrocarbons Engineering.

Introducción

La tomografía computarizada de rayos-X es una técnica que se usa en la descripción y caracterización petrofísica de muestras de yacimiento. Es una herramienta que ofrece muchas ventajas comparada con los métodos convencionales, ya que permite evaluar la estructura interna de las muestras sin afectar su integridad, proporcionando información cualitativa y cuantitativa.

Gracias a los avances en desarrollo e investigación de esta técnica, actualmente es posible estimar propiedades petrofísicas básicas de las muestras a un nivel de muy alta resolución, en comparación a los datos de registros de pozo. Sin embargo, estos modelos para estimar propiedades petrofísicas básicas sólo aplican para los datos que resultan de imágenes de tomografía obtenidos a partir de muestras de núcleos y tapones.

Este proyecto pretende desarrollar un modelo para integrar datos de tomografía a los métodos de estimación de propiedades petrofísicas básicas a partir de registros, mediante el uso de un modelo de redes neuronales.

2. Objetivos

2.1 Objetivo General

Desarrollar un modelo para la integración de registros de pozo con información de tomografía para la estimación de propiedades petrofísicas por medio de un modelo de redes neuronales.

2.2 Objetivos Específicos

- Recolectar información de registros de pozo e imágenes de tomografía para un pozo de estudio.
- Establecer relaciones teóricas entre los datos obtenidos en tomografía, la información de registros de pozo y las propiedades petrofísicas básicas.
- Desarrollar un método de estimación de propiedades petrofísicas básicas a partir de registros mediante un modelo de redes neuronales.
- Definir un modelo que permita integrar los datos de tomografía al método de estimación de propiedades petrofísicas básicas usando registros de pozo.

3. Marco Referencial

3.1 Escaneo con Energía Dual de Tomografía Computarizada

El escaneo con energía dual de tomografía computarizada es una técnica que permite la evaluación de muestras de yacimiento sin afectar su integridad, mediante el uso de rayos-X a alta y baja energía (Siddiqui & Khamees, 2004). Su aplicación básica en la industria de los hidrocarburos es servir de apoyo en la descripción y caracterización de rocas, tanto de manera cualitativa como de manera cuantitativa (Ortiz, A. *et al.*, 2015).

La tomografía computarizada genera registros de mucha más alta resolución en comparación a los registros de pozo convencionales: 0,002 ft vs 0,5 ft (Siddiqui & Khames). Además, el equipo de tomografía computarizada está compuesto por materiales que soportan altas presiones y temperaturas, lo que permite simular las condiciones del yacimiento.

3.1.1 Principio Físico del Escaneo con Energía Dual

Esta técnica consiste en escanear una muestra dos veces en el mismo punto usando una configuración de alta y otra de baja energía, las cuales aprovechan las dos interacciones predominantes entre los rayos-X y la materia: la absorción fotoeléctrica (predominante a bajas energías) y la dispersión Compton (predominante a altas energías). La probabilidad de la absorción fotoeléctrica incrementa con el número atómico y la probabilidad de la dispersión Compton depende de la densidad eléctrica; por lo tanto, es posible calcular el número atómico efectivo y la densidad eléctrica de un material mediante el escaneo a dos niveles de energía con suficiente diferencia.

Wellington & Vinegar (1987) establecieron que a partir del escaneo de una muestra a altas y bajas energías de rayos-X se puede obtener una imagen proporcional a la densidad aparente y otra proporcional al número atómico (Siddiqui & Khamees, 2004). De esta manera, presentaron este concepto a través de unas ecuaciones que, aunque eran de naturaleza no lineal, mostraban una relación entre la información de tomografía y estas dos propiedades (Ecuaciones 2., 3. Y 4.).

$$\mu = \rho \left[a + \frac{bZ^n}{E^{3.2}} \right] \dots\dots\dots(1)$$

Donde, μ es el coeficiente de atenuación lineal (parámetro medido por el escáner), ρ es la densidad electrónica, Z es el número atómico, E es la energía de rayos-X, a y b son constantes que relacionan la densidad aparente con el coeficiente de atenuación lineal, y n es el exponente para el número atómico (Z).

$$\rho_b = 1.0704\rho - 1.1883 \dots\dots\dots(2)$$

Donde, ρ_b es la densidad aparente o densidad total (*bulk density*).

$$Z_{eff} = \left[\sum f_i Z_i^n \right]^{1/n} \dots\dots\dots(3)$$

Donde, Z_{eff} es el número atómico efectivo, f_i es la fracción atómica del i -ésimo elemento en el compuesto, y Z_i es el número atómico del i -ésimo elemento en el compuesto.

$$P_e = \left[\frac{Z_{eff}}{10} \right]^n \dots\dots\dots(4)$$

Donde, P_e es el factor fotoeléctrico.

Vinegar & Kehl (1988) desarrollaron unas ecuaciones lineales (Ecuaciones 6. y 7.) y sugirieron escanear *fantasmas* (muestras de calibración) con valores de densidad aparente y

número atómico conocidos. Posteriormente, se debían usar los datos obtenidos de este escaneo en las ecuaciones, para calcular los coeficientes que luego serían usados en la estimación de los valores de densidad aparente y número atómico de las muestras desconocidas (Siddiqui & Khamees, 2004).

$$CTN = \frac{\mu - \mu_w}{\mu_w} * 1000 \dots\dots\dots(5)$$

Donde, *CTN* son números CT que representan los términos a través de los cuales se proporcionan los datos de atenuación, μ .

$$\rho = A * CTN_{low} - B * CTN_{high} + C \dots\dots\dots(6)$$

Donde, *CTN_{low}* y *CTN_{high}* corresponden a los *CTN* medidos a baja y alta energía, respectivamente, mientras que A, B y C son los coeficientes que deben ser calculados a partir de los fantasmas.

$$Z_{eff} = D \left[\frac{E * CTN_{low} - CTN_{high} - F}{\rho} \right]^{1/n} \dots\dots\dots(7)$$

Por otra parte, Siddiqui & Khamees (2004) formularon procedimientos simples para calcular los coeficientes necesarios y poder determinar los valores de densidad aparente y número atómico efectivo (Ecuaciones 8. Y 9.), basados en datos ROI (*Region of Interest*) de cortes seccionales a alta y baja energía. Además, presentaron un flujo de trabajo para la estimación de porosidad a partir de estos valores de densidad y número atómico, obtenidos del escaneo con energía dual.

$$\rho_b = m * CTN_{low} + p * CTN_{high} + q \dots\dots\dots(8)$$

$$Z_{eff} = \left[\frac{r * CTN_{low} + s * CTN_{high} + t}{0,9342 * \rho_b + 0,1759} \right]^{1/n} \dots\dots\dots(9)$$

$$RHOB = \rho_g(1 - \phi) + \rho_f * \phi \dots\dots\dots(10)$$

$$PEF = \left[\frac{Z_{eff}}{10} \right]^n \dots\dots\dots(11)$$


Donde, $RHOB$ es la densidad aparente o densidad total (ρ_b), PEF es el factor fotoeléctrico (P_e) y ϕ es la porosidad absoluta.

3.1.2 El Escáner de Tomografía Computarizada

El escáner tiene una fuente de rayos-X rotando y 1.200 detectores. Lo que miden los equipos de tomografía son grados de atenuación (Ecuación 1.) en función de la composición atómica de las muestras. Las imágenes obtenidas de las muestras son representaciones gráficas de los diferentes coeficientes de atenuación que tienen éstas (Ortiz, A. *et al.*, 2015), así que el escáner genera los datos en una matriz de coeficientes y son discretizados en pequeñas unidades donde cada elemento se llama vóxel (equivalente a un pixel en 3D).

Figura 1

Configuración de un Escáner de Tomografía Computarizada



Nota. Izquierda: equipo de tercera generación. Derecha: equipo de cuarta generación. Tomado de Ortiz, A. et al., 2015.

El principio físico de la técnica es escanear dos veces en un mismo punto de la muestra con suficiente diferencia de energía, por esta razón, el equipo debe ser un escáner de energía graduable, de manera que se pueda escanear a energía alta (mayor a 100 kV) y energía baja (menor a 100 kV). En la Figura 1 se observa un esquema del funcionamiento los modelos de tercera y cuarta generación de escáneres usados en la Tomografía Computarizada.

3.2 Relaciones Teóricas entre Tomografía, Registros y las Propiedades Petrofísicas Básicas

Para obtener resultados satisfactorios a partir de un modelo de aprendizaje automático, es necesario que exista una relación entre los datos de entrada (*input dataset*) y los datos de salida (*target output dataset*).

En principio, los parámetros medidos por el escáner (coeficientes de atenuación lineal, llevados a números CT o CTN) a alta y baja energía, están relacionados con la densidad aparente y el número atómico efectivo. Por lo tanto, se pueden calcular los valores de RHOB y PEF a partir

de estas mediciones. Esta técnica ha mostrado buenos resultados, obteniendo valores estimados de RHOB de las muestras, con menos de 3% de error relativo (Ortiz, A. *et al.*, 2020). Siddiqui & Khamees (2004), además de describir el procedimiento para el cálculo de estas dos variables, muestra un paso a paso para el cálculo de la porosidad.

Se han propuesto varios enfoques para determinar la porosidad a partir de información de tomografía; algunos utilizando escaneo con energía dual (Akin *et al.*, 1996) o escaneo simple (Akin *et al.*, 2000), y otros usando imágenes CT de muestras de núcleos en diferentes estados (seco y saturado) para generar mapas de porosidad 3D (Larmagnat *et al.*, 2019). Sin embargo, en la mayoría de los casos la porosidad es estimada a partir de la RHOB y el PEF. El PEF no se ve afectado directamente por la porosidad, pero sí es una función de la litología que está relacionada con la densidad de grano, por lo que está involucrada en la relación entre la porosidad y la RHOB. Por lo tanto, incluir el PEF en las estimaciones permite definir cambios en la relación entre la RHOB y la porosidad, cuando cambia la litología (Ortiz, A. *et al.*, 2020).

Siddiqui & Khamees (2004) proponen establecer un valor de densidad de grano en función de la litología, la cual es determinada a partir de los valores de PEF y rangos definidos en estudios como cartas de interpretación de registros. Luego, con los valores de RHOB definidos, calcular la porosidad a partir de la definición de densidad total:

$$\phi = \frac{\rho_g - \rho_b}{\rho_g - \rho_f} \dots\dots\dots(12)$$

Donde, ρ_g es la densidad de grano, ρ_f es la densidad del fluido que satura la muestra y ρ_b es la densidad aparente o total.

Ortiz, A. *et al.* (2015) también propone un método para el cálculo de la porosidad efectiva en plugs, basado en las ecuaciones expuestas por Funk, J., Withjack, E. & Siddiqui, S. (2011) y

Coles, M. et al. (1995). La ventaja de este método es que no depende de la determinación de otras propiedades como la densidad de grano o la litología, y consiste en realizar tomografía al plug a dos estados de saturación diferentes (escaneando la muestra por dos tipos de fluido). Para esto, se deben adquirir las imágenes de tomografía a un nivel de energía alto (adquisición 1) usando un fantasma con el mismo líquido que satura la muestra. Luego, se debe saturar totalmente la muestra con salmuera o agua destilada y escanear al mismo nivel de energía que antes (adquisición 2). De cada adquisición de imágenes se obtienen los valores de números CT correspondientes para la adquisición 1, la adquisición 2, el fantasma y el aire en la adquisición 1. Con estos valores, se puede aplicar el cálculo de la porosidad efectiva vóxel a vóxel o corte a corte.

$$\phi = \frac{CTN^1 - CTN^2}{CTN_{aire}^1 - CTN_{fan}^1} \dots\dots\dots(13)$$

Donde, CTN^1 es el número CT (coeficiente de atenuación) en el vóxel o el corte en la adquisición 1, CTN^2 es el coeficiente de atenuación en el vóxel o el corte en la adquisición 2, CTN_{fan}^1 es la atenuación del fantasma en la adquisición 1 y CTN_{aire}^1 es la atenuación del aire en la adquisición 1.

Las definiciones anteriores evidencian que es posible relacionar los datos que se obtienen de las imágenes de tomografía con la porosidad.

Por otra parte, la permeabilidad se puede correlacionar con la porosidad mediante la ecuación de Winland, la cual ha mostrado buenos resultados para yacimientos de hidrocarburos en trampas estratigráficas (Pittman, E., 1992). H. D. Winland desarrolló esta correlación empírica entre la porosidad, la permeabilidad al aire y la apertura de poro correspondiente a una saturación de mercurio del 35%, para una mezcla de areniscas y carbonatos.

$$\log r_{35} = 0.732 + 0.588 \log K_{air} - 0.864 \log \phi \quad \dots\dots\dots(14)$$

Donde r_{35} es el radio de apertura del pozo correspondiente al percentil 35, K_{air} es la permeabilidad al aire (md) y ϕ es la porosidad (%).

El procedimiento consiste en discretizar tipos de roca o unidades de flujo mediante los resultados de los radios de apertura y relacionando valores de permeabilidad y porosidad.

Además, el estudio de Sudakov et al. (2019) mostró que la permeabilidad puede ser evaluada vóxel a vóxel mediante las imágenes de tomografía de núcleos, y Kohli & Arora (2014) formularon un procedimiento para estimar la permeabilidad a partir de registros de pozo, pero usando un modelo de redes neuronales.

Ahora bien, también es posible estimar la porosidad a partir de otras mediciones indirectas, como los registros. Sin embargo, un solo registro no puede proporcionar una estimación confiable (Carrasquilla et al., 2017), ya que dependen de varias formas de interacción entre la litología, el tipo de fluido, la geometría porosa y las propiedades físicas (Abreu, 2015). Por lo tanto, es común utilizar más de un registro, con el fin de alcanzar una mejor estimación de la porosidad.

Los perfiles de Rayos Gamma (GR) y potencial espontáneo (SP) nos permiten describir la litología de las formaciones, el perfil de resistividad junto con el registro SP son de gran ayuda para conocer el tipo de fluido que existe dentro de la formación, mientras que los perfiles de Porosidad Neutron (NPHI), Densidad (RHOB) y Sónico (DT) son los que nos brindan información para hacer las estimaciones de la porosidad, con ayuda de la descripción litológica que se realiza a partir de los perfiles GR y SP.

Para el registro Sónico (DT), se introduce una herramienta que emite una onda, la cual viaja a través de la formación y de esta manera nos da una idea de su porosidad, ya que el tiempo de tránsito de la onda depende principalmente del tipo de litología que existe y de la porosidad.

Wyllie et al (1956) propusieron a partir de varias pruebas de laboratorio una relación lineal entre el tiempo de tránsito y la porosidad.

$$\Delta t = \Delta t_{fl} * \phi - \Delta t_{ma}(1 - \phi - V_{sh}) - \Delta t_{sh} * V_{sh} \dots\dots\dots(15)$$

Donde, Δt es la lectura del perfil sónico ($\mu s/ft$), Δt_{ma} es el tiempo de tránsito en la roca matriz, Δt_{fl} es la velocidad del sonido en el fluido de la formación, ϕ es la porosidad, Δt_{sh} es el tiempo de tránsito en las arcillas y V_{sh} es el contenido de arcillas.

En arenas consolidadas y compactas, cuando las formaciones son limpias y con pequeños poros distribuidos uniformemente, la ecuación propuesta por Wyllie se reduce a:

$$\Delta t = \Delta t_{fl} * \phi - \Delta t_{ma}(1 - \phi) \dots\dots\dots(16)$$

De donde se obtiene la porosidad:

$$\phi = \frac{\Delta t - \Delta t_{ma}}{\Delta t_{fl} - \Delta t_{ma}} \dots\dots\dots(17)$$

Para el registro de Densidad (RHOB), se sigue un principio similar al que se utiliza cuando se tiene información de tomografía: las diferentes formas de interacción entre los rayos gamma y la materia, las cuales dependen básicamente del nivel de energía de estos.

Este tipo de perfil también se utiliza principalmente en la evaluación de la porosidad de las formaciones. Además, cuando se hace una combinación de este registro con el registro Neutron, se pueden cuantificar acumulaciones de gas.

El cálculo de la porosidad por medio del registro de Densidad para una formación limpia con densidad de matriz y densidad del fluido de la formación conocidos está dado por la siguiente ecuación:

$$\phi = \frac{\rho_b - \rho_{ma}}{\rho_{fl} - \rho_{ma}} \dots\dots\dots(18)$$

Donde, ρ_b es la densidad aparente o densidad total (*bulk density*), ρ_{fl} es la densidad del fluido, ρ_{ma} es la densidad de la roca matriz y ϕ es la porosidad.

Finalmente, para la evaluación de formaciones por medio del registro Neutron (NPHI), se introduce una herramienta que emite constantemente neutrones de alta energía desde una fuente radioactiva, los cuales chocan con los materiales de la formación, semejante a una colisión elástica.

Este registro, al igual que los dos anteriores, es utilizado para ubicar formaciones porosas y establecer cuantitativamente esta propiedad. En principio, responden a la cantidad de hidrógeno presente en los poros de una formación, lo que indica que cuando hay presencia de hidrocarburos o de agua, pueden proveer valores muy aproximados al valor real de porosidad. Sin embargo, la combinación con los otros registros permite obtener valores más exactos de porosidad y facilitan la evaluación del contenido de arcillas.

Los valores de porosidad que se calculan del perfil Neutron pueden ser aparentes siempre y cuando se tomen ciertas suposiciones y se hagan ciertas correcciones. Los valores que se obtienen de este registro son mediciones de porosidad aproximada que se realizan a través de calibraciones con muestras de porosidad conocida.

A continuación, se presenta un resumen de los enfoques para el cálculo de la porosidad a partir de los perfiles de Porosidad Neutron (NPHI), Densidad (RHOB) y Sónico (DT), propuesto por Carrasquilla et al. (2017). Adicionalmente, incluye el enfoque a partir del registro de

Resonancia Magnética Nuclear (RMN) y un modelo de regresión que agrupa todos estos modelos de estimación de la porosidad, propuesto por Coates et al. (1999).

Tabla 1

Resumen de estimaciones de porosidad a partir de registros

Registro	Datos requeridos	Ecuación/Correlación	Referencia
Neutron	Calibración de la herramienta con muestras de porosidad conocida	ϕ_{nphi}	Scott et al. (1994)
Densidad	Densidades de la roca matriz (ρ_{ma}) y del fluido (ρ_{fl})	$\phi_{rhob} = \frac{\rho_b - \rho_{ma}}{\rho_{fl} - \rho_{ma}}$	Schlumberger (2013)
Sonico	Tiempos de tránsito de la roca matriz (Δt_{ma}) y del fluido (Δt_{fl})	$\phi_{\Delta t} = \frac{\Delta t - \Delta t_{ma}}{\Delta t_{fl} - \Delta t_{ma}}$	Wyllie et al. (1956)
Densidad + Neutron	Densidades de la roca matriz y del fluido para el registro de densidad y calibración de la herramienta para el registro neutron	$\phi_t = \sqrt{\frac{\phi_{rhob}^2 + \phi_{nphi}^2}{2}}$	Alberty (1994)
RMN	Índice de hidrógeno usando tiempos de relajación T_1 y T_2	ϕ_{rmn}	Coates et al. (1999)
Regresión	$\phi_{rhob}, \phi_{nphi}, \phi_{\Delta t}, \phi_{nmr}$	$\phi_{reg} = -0.007 + 0.407\phi_{rhob} + 0.191\phi_{nphi} + 0.051\phi_{\Delta t} + 0.303\phi_{rmn}$	Abreu (2015)

Nota. Tomado de Carrasquilla et al., 2017.

Para el caso de la permeabilidad, existen muchos enfoques que permiten derivar esta propiedad a partir de los registros. El registro de RMN tiene la capacidad de estimar la permeabilidad de la formación con base en una combinación de modelos teóricos y modelos basados en muestras de núcleos que sugieren que crece con el aumento de la porosidad y el tamaño

de los poros (Carrasquilla et al., 2017). Con este registro, se calcula la permeabilidad a partir de las medidas de porosidad espectral usando diferentes relaciones, creadas a partir de estos modelos.

Tabla 2

Resumen de estimaciones de permeabilidad (mD) a partir de registros

Registro	Datos requeridos	Ecuación/Correlación	Referencia
Resistividad + registros de porosidad o RMN	$\phi_t, S_{wirr}, a_1 = 10^4, b_1 = 4.4$ y $c_1 = 2$	$k_{timur} = a_1 \frac{\phi_T^{b_1}}{S_{wirr}^{c_1}}$	Timur (1968)
RMN	ϕ_{rmn} , BVM (fluido móvil), BVI (agua irreducible), $a_2 = 4, b_2 = 2$ y $6 < c_2 < 15$	$k_{coates} = \left(\frac{\phi_{rmn}}{c_2}\right)^{a_2} \left(\frac{BVM}{BVI}\right)^{b_2}$	Coates et al. (1999)
RMN	T_{2gm} , $a_3 =$ variable dependiente de la formación, $b_3 = 4$ y $c_3 = 2$	$k_{sdr} = a_3 \phi_{rmn}^{b_3} T_{2gm}^{c_3}$	Schlumberger (2013)
Regresión	$k_{timur}, k_{coates}, k_{sdr}$	$k_{reg} = -0.007 + 1.1235k_{timur} - 0.0007k_{timur}^2 + 0.7497k_{coates} + 0.0003k_{coates}^2 - 0.1689k_{sdr} + 18.6700k_{sdr}^2$	Tavares (2015)

Nota. Tomado de Carrasquilla et al., 2017.

3.3 Aplicación de los Modelos de Redes Neuronales

Los modelos teóricos y las correlaciones nos permiten describir analíticamente las relaciones entre propiedades o parámetros cuantitativos dados. La manera más práctica en la que se habían desarrollado estos modelos era mediante pruebas de laboratorio y posteriormente a través de análisis complejos. En este proyecto se definieron modelos de predicción haciendo uso de otras

herramientas: las redes neuronales artificiales (*ANN, Artificial Neural Networks - RNA*). Estas nos permiten crear modelos predictivos a partir del entrenamiento con datos conocidos (*observaciones*), y también evaluar fácilmente su rendimiento.

Las RNA son modelos computacionales que se caracterizan por procesar información y aprender a resolver problemas a través de la experiencia. Son capaces de desarrollar patrones de forma inductiva por medio de algoritmos de aprendizaje basados en patrones de entrenamiento, y no requiriendo la ayuda de un modelador (Salas, R., 2015). En otras palabras, usan métodos computacionales para “aprender” la información directamente a partir de los datos sin depender de una ecuación predeterminada como modelo. Sin embargo, dependen de la información con la que se cuenta para el entrenamiento, ya que los algoritmos naturalmente mejoran su rendimiento a la vez que el número de datos disponible incrementa.

Las diferentes clases de RNA se distinguen entre sí por los siguientes elementos:

- Las neuronas, que constituyen el elemento básico de procesamiento (diferenciadas principalmente por su función de activación¹).
- La arquitectura de la red, descrita por las conexiones ponderadas entre las neuronas (aunque se puede definir por el número de capas, la arquitectura de la red se diferencia principalmente por el modelo de aprendizaje²).

¹ Funciones de activación: la más usada es la función de transferencia tangente sigmoidea hiperbólica, pero dependiendo del modelo y los datos usados para el entrenamiento también se suelen usar la función de transferencia sigmoidea logarítmica y la función de transferencia sigmoidea de Elliot.

² Modelos de aprendizaje: constituyen los dos grandes de modelos usados en la aplicación de redes neuronales; el aprendizaje automático (*Machine Learning*) y el aprendizaje profundo (*Deep Learning*).

- El algoritmo de entrenamiento, usado para encontrar los parámetros de la red (esta función o algoritmo de entrenamiento³ estará definido por la robustez del modelo; si se desea entrenar un modelo simple, o más ajustado y que generalice bien).

El modelo de aprendizaje requerido para el entrenamiento de una red neuronal dependerá del tipo de información con la que se desea trabajar. Los modelos de aprendizaje automático (*Machine Learning*) están diseñados para procesar datos lineales (como valores numéricos); la arquitectura que definen este tipo de modelos son los Perceptrones Multicapa (*PMC*). Por otra parte, los modelos de aprendizaje profundo (*Deep Learning*) son un tipo de aprendizaje automático que se caracterizan por ser capaces de realizar procesos más complejos como identificar objetos, clasificarlos o incluso generar textos y secuencias de textos coherentes; estos modelos están definidos principalmente por dos tipos de arquitecturas: las Redes Neuronales Convolucionales (*RNC*), usadas principalmente para procesar datos espaciales (como imágenes) y las Redes Neuronales Recurrentes (*RNR*), que procesan datos secuenciales (como texto).

La parte más importante de un modelo de *Machine Learning* es el aprendizaje. El esquema de aprendizaje de una red es lo que determina el tipo de problema que será capaz de resolver. Son sistemas basados en ejemplos, por lo tanto, su capacidad para resolver problemas está ligada de forma fundamental al tipo de ejemplos que dispone en el proceso de aprendizaje.

El *Machine Learning* usa dos tipos de técnicas: *i*) Aprendizaje Supervisado, el cual entrena un modelo a partir de datos de entrada y salida conocidos, y puede entonces predecir datos de


³ Algoritmo de entrenamiento: el más usado por su capacidad de procesar la información rápidamente es el algoritmo de retropropagación (*backpropagation*) de Levenberg-Marquardt, pero cuando se prefiere producir una red que generalice bien se suele usar el proceso de Regularización Bayesiana.

salida futuros; y *ii*) Aprendizaje No Supervisado, que identifica patrones ocultos o estructuras intrínsecas en los datos de entrada.

El aprendizaje supervisado consiste en entrenar la red a partir de un conjunto de datos compuesto por patrones de entrada y salida. El objetivo del algoritmo de aprendizaje es ajustar los parámetros de la red, de manera tal que la salida generada por la RNA sea lo más cercana posible a la verdadera salida, dada una cierta entrada (Isasi, P. & Galván, I. M., 2004). La Figura 2 muestra una representación de este tipo de aprendizaje.


Figura 2

Aprendizaje supervisado

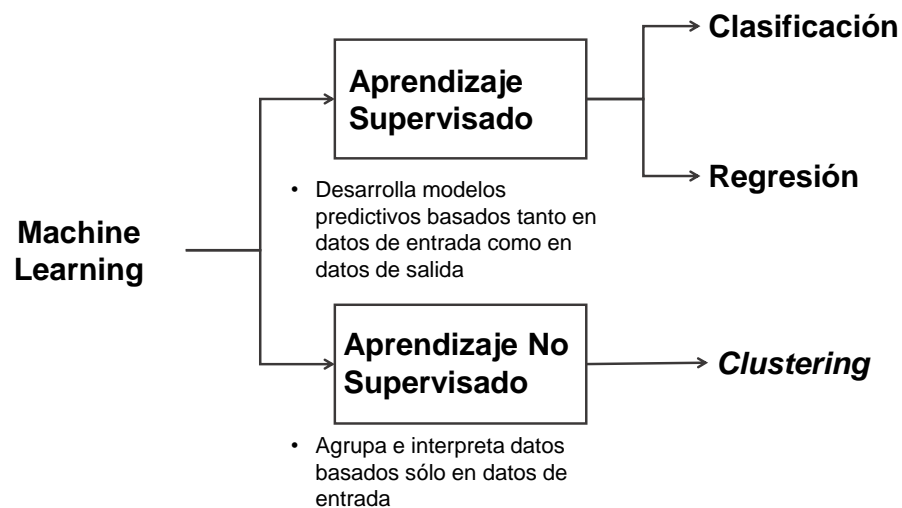


Nota. Tomado de Isasi, P. & Galván, I. M., 2004.

Mientras que, en el aprendizaje no supervisado se presenta sólo un conjunto de patrones de la RNA y el objetivo del algoritmo de aprendizaje es ajustar los pesos de la red, de manera tal que la red encuentre alguna estructura o configuración presente en los datos, tal como se muestra en la Figura 3.

Figura 3*Aprendizaje no supervisado**Nota.* Tomado de Isasi, P. & Galván, I. M., 2004.

Cada técnica puede usarse para resolver un tipo de problema específico. El aprendizaje supervisado nos permite diseñar modelos para *clasificación* y también para modelos de *regresión*, por otra parte, el aprendizaje no supervisado nos ayuda a generar modelos de *agrupamiento* (*clustering*). En la Figura 4 se observa un esquema que resume estas relaciones.

Figura 4*Aplicaciones de los esquemas de aprendizaje para un modelo de aprendizaje automático**Nota.* Tomado de matlabacademy.mathworks.com/Machine Learning with Matlab.

El ejemplo más simple de los modelos de aprendizaje supervisado son las regresiones lineales, donde el objetivo es construir un sistema que pueda tomar un dato de entrada x y predecir un dato de salida y . A diferencia de un modelo de regresión convencional, para construir estos sistemas de predicción los modelos de aprendizaje automático utilizan unas estructuras conocidas como *feed-forward networks*, las cuales serán usadas para los términos de este proyecto.


3.3.1 La Neurona Artificial

La neurona artificial es un elemento que posee un nivel de activación y recibe señales que le permiten, en su caso, cambiar de estado. Las neuronas poseen una función que les permite cambiar de nivel de activación a partir de las señales (datos de entrada) que reciben (Isasi, P. & Galván, I. M., 2004).

Mc Culloch & Pitts (1943) concibieron un modelo abstracto y simple de una neurona artificial, que es el elemento básico de procesamiento en una red neuronal artificial. En la Figura 5 se muestra su esquema.

Figura 5

Esquema de una unidad neuronal artificial típica



Nota. Tomado de Isasi, P. & Galván, I. M., 2004.

Aquí, un grupo de datos de entrada x_1, x_2, \dots, x_n son introducidos en la neurona artificial. Cada dato de entrada se multiplica por un peso asociado w_1, w_2, \dots, w_n , y el resultado E es la suma de todas las entradas ponderadas algebraicamente.

$$E = x_1w_1 + x_2w_2 + \dots + x_nw_n \dots\dots\dots(19)$$

Este resultado, es procesado además por una función llamada *función de activación*, que produce la señal de salida de la neurona, S . Dependiendo de la función de activación, habrá distintos modelos de aprendizaje.


$$S = F(E) \dots\dots\dots(20)$$

3.3.2 Perceptrones Multicapa

Los PMC constituyen la clase de RNA más estudiada y la más común en los campos de aplicación (Salas, R., 2015). Su arquitectura se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida; como se observa en la Figura 6.

Figura 6

Arquitectura del perceptrón multicapa



Nota. Tomado de Isasi, P. & Galván, I. M., 2004.

Las conexiones del PMC siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan con las neuronas de la siguiente capa. De ahí que también reciban el nombre de *feed-forward networks* o redes alimentadas hacia adelante (Isasi, P. & Galván, I. M., 2004).

En este modelo, a las neuronas de entrada se les asignan pesos aleatorios dentro de un rango determinado ($[0,1]$ o $[-1,1]$ dependiendo de la función de transferencia usada), la función de activación de la capa de entrada convoluciona los pesos de las neuronas con los datos de entrada. Esto se pasa a la capa oculta, donde el producto de los pesos de los datos de entrada de la capa anterior se integra con la función de activación de esa capa. Posteriormente, el valor se pasa a la siguiente capa o en su defecto, a la capa de salida.

La red genera una salida y la compara con el conjunto de datos de salida objetivo. Usando el algoritmo de aprendizaje de retropropagación (*backpropagation*), la red itera y se actualizan los pesos de las neuronas de entrada, salida y capas ocultas. Las iteraciones continúan hasta que se alcance el error objetivo (Kohli & Arora, 2014).

Un problema común que ocurre durante el entrenamiento de este tipo de redes neuronales es el sobreajuste de datos (*over-fitting*), donde la red tiende a memorizar los ejemplos de entrenamiento, sin aprender a generalizar a más situaciones. Esto sucede cuando el entrenamiento excede el límite requerido. Para solucionar este problema, el conjunto de datos se divide en tres subconjuntos: *i*) el conjunto de entrenamiento (*training set*), que se utiliza para calcular el gradiente y actualizar los pesos de la red; *ii*) el conjunto de validación (*validation set*), cuyo error se monitorea durante el proceso de entrenamiento, ya que tiende a aumentar cuando los datos están sobreajustados; *iii*) el conjunto de prueba (*test set*), cuyo error se puede utilizar para evaluar la calidad de la división del conjunto de datos.

3.4 Modelos de Redes Neuronales usados para estimar Propiedades Petrofísicas a partir de Tomografía y a partir de Registros

Ortiz, A. et al. (2020) desarrollaron un script de Matlab para identificar RHOB y valores de PEF para cada muestra a partir de los registros de alta resolución y coeficientes de atenuación medidos. Luego, usando otro script generaron y entrenaron redes neuronales multicapas, a partir de datos conocidos y las herramientas de entrenamiento de Matlab. Este script permite al usuario seleccionar la topología para crear y entrenar nuevas redes neuronales; en cada caso, permite ver gráficos de regresión de datos previstos frente a datos reales para que el usuario pueda evaluar el rendimiento de la red neuronal. En este modelo, las redes creadas usan funciones de transferencia hiperbólica tangente sigmoidea como funciones de activación, y se entrenan usando el algoritmo de aprendizaje *backpropagation* de Levenberg-Marquadt.

Se llevó a cabo la predicción de la porosidad para cada sección central del pozo, utilizando tres capas ocultas y diez neuronas que mostraron un buen desempeño en los gráficos de regresión. Además, se obtuvieron gráficos de porosidad para cada sección del núcleo y en todos ellos los valores predichos son cercanos a los reales y mostraron una buena concordancia con las imágenes CT (Ortiz, A. et al., 2020).

Morris, E. (2021) diseñó un modelo de aprendizaje profundo para estimar porosidad y permeabilidad, en el que contó con un conjunto de datos de 36 imágenes de tomografía computarizada de secciones de núcleos de perforación de 3 ft, con sus respectivos datos de RHOB y PEF, que fueron proporcionados para el entrenamiento, pruebas y validación del modelo. El modelo fue desarrollado en Python 3.7, con el que se pudieron concatenar los modelos de cada tipo de información (datos numéricos e imágenes de tomografía) en un solo modelo robusto.

El análisis de la métrica de los modelos de porosidad y permeabilidad mostraron buenos resultados, lo que representa un modelo robusto de predicción válido a partir de datos numéricos e imágenes de tomografía.

Un modelo de redes neuronales con algoritmo de aprendizaje *backpropagation* también fue desarrollado por Kohli & Arora (2014), pero para estimar propiedades petrofísicas alimentándose con datos de registros Gamma-Ray, Resistividad, densidad y Porosidad; cada uno en una neurona de la capa de entrada. La red cuenta con una capa de entrada que usa la función de activación *tangente sigmoidea* y una capa oculta que usa la función de activación *purelin*. La capa oculta se conecta con la capa de salida que consta de una sola neurona. El algoritmo de entrenamiento usado es Levenberg-Marquardt y el cálculo de errores se realiza a través del algoritmo del cuadrado medio.

En este estudio se usaron los registros de dos pozos para entrenar y validar el modelo de predicción de permeabilidad. Pero, además el modelo se usó para predecir la permeabilidad de un tercer pozo y los resultados obtenidos fueron exitosos (Kohli & Arora, 2014).

4. Reporte de la información recolectada de Registros y Tomografía

Se recolectaron datos de registros, tomografía y propiedades petrofísicas básicas de tres pozos de un campo colombiano. La información se obtuvo por cortesía de Ecopetrol S.A.

Tabla 3

Información recolectada de registros, tomografía y datos petrofísicos

Registros	
Pozo-1	<ul style="list-style-type: none"> ▪ Registros litológicos, petrofísicos y resistivos⁴ (Formación A, 1515 – 5663 ft; con una resolución vertical de 0.25 ft para un total de 16593 datos por registro).
Pozo-2	<ul style="list-style-type: none"> ▪ Registros litológicos, petrofísicos y resistivos (Formación A, 1500 – 5128.25 ft; con una resolución vertical de 0.25 ft para un total de 14594 datos por registro).
Pozo-3	<ul style="list-style-type: none"> ▪ Registros litológicos, petrofísicos y resistivos (Formación A, 1310 – 5186 ft; con una resolución vertical de 0.25 ft para un total de 15505 datos por registro).
Tomografía	
Pozo-1	<ul style="list-style-type: none"> ▪ Imágenes de cortes XZ y registros individuales⁵ (Formación A, 8 cores que incluyen 94 secciones de 3 ft extraídos entre 674 – 4648 ft; con una resolución de 0.625 mm para un total de 1463 datos por sección y 137522 datos en total).

⁴ Registros litológicos, petrofísicos y resistivos: Gamma Ray (GR), Spontaneous Potential (SP), Field normalized compensated Neutron Porosity (NPHI), Formation Bulk Density (RHOB), Photo electric cross-section (PEF), Resistivity (LLD).

⁵ Registros individuales (registros por secciones de 3 ft): densidad aparente (RHOB), factor fotoeléctrico (PEF), número atómico efectivo (Zeff).

- Pozo-2
- Imágenes de cortes XZ y registros individuales (Formación A, 4 cores que incluyen 36 secciones de 3 ft extraídos entre 4224 – 4791 ft; con una resolución de 0.625 mm para un total de 1463 datos por sección y 52668 datos en total).
- Pozo-3
- Imágenes de cortes XZ y registros individuales (Formación A, 8 cores que incluyen 80 secciones de 3 ft extraídos entre 3655 – 4621 ft; con una resolución de 0.625 mm para un total de 1463 datos por sección y 117040 datos en total).

Datos petrofísicos

- Pozo-1
- Propiedades petrofísicas básicas⁶ (Formación A, 4528.5 – 4642.4 ft; con muestras entre 2.7 – 6.7 cm de longitud para un total de 48 datos).
- Pozo-2
- Propiedades petrofísicas básicas (Formación A, 4224.46 – 4783.7 ft; con muestras entre 3.0 – 7.0 cm de longitud para un total de 62 datos).
- Pozo-3
- Propiedades petrofísicas básicas (Formación A, 3745.2 – 4264.6 ft; con muestras entre 1.3 – 6.2 cm de longitud para un total de 125 datos).

⁶ Propiedades petrofísicas básicas: volumen total, volumen poroso, volumen de granos, densidad de granos, porosidad RCAL, permeabilidad Klinkenberg, permeabilidad al aire, saturación de crudo, saturación de agua, densidad total.

5. Desarrollo de los Modelos de Estimación de Propiedades Petrofísicas Básicas a partir de Registros e Integrando Información de Tomografía

El tipo de información que se empleó en los modelos es numérico, por lo tanto, se usaron PMC como arquitectura para los modelos de predicción de las propiedades petrofísicas básicas. Más específicamente, unas arquitecturas de redes neuronales conocidas como *feed-forward regression networks*, las cuales son muy útiles en la predicción de problemas de aprendizaje supervisado, donde el objetivo es desarrollar un modelo evaluando un set de datos de entrada dado un set de datos de salida, principalmente numéricos.

En este caso, para los modelos de predicción los datos de entrada fueron datos de registros mientras que los datos de salida fueron los valores de porosidad o permeabilidad, según el modelo. Por otra parte, para los modelos de integración los datos de entrada que se integraron a los modelos de predicción fueron los valores numéricos de propiedades extraídas de las imágenes de tomografía (RHOB y PEF).


Los modelos de regresión *feed-forward network* fueron desarrollados en Matlab. El software nos permite evaluar rápidamente los modelos a través de parámetros de regresión. Para cada modelo, el objetivo es encontrar la arquitectura y topología más adecuada que se ajuste a los datos de entrenamiento y que también permita obtener la mejor estimación de propiedades petrofísicas en pruebas futuras.

Como se mencionó anteriormente, el monitoreo del rendimiento del modelo con los conjuntos de datos para entrenamiento, validación y prueba permiten evaluarlo para evitar el *overfitting* o sobreajuste de datos, el cual se presenta cuando el modelo predice muy bien los datos de salida con los datos usados para el entrenamiento, pero no generaliza muy bien para otras

observaciones. Generalmente sucede cuando se exceden las iteraciones para ajustar el modelo a los datos usados para el entrenamiento de la red neuronal. En la Figura 7 se muestra una representación de este concepto.

Figura 7

Parámetros para la evaluación de modelos por over-fitting o sobreajuste de datos




Nota. Tomado de [matlabacademy.mathworks.com/Machine Learning with Matlab](https://matlabacademy.mathworks.com/Machine-Learning-with-Matlab)

5.1 Modelos de Predicción de Porosidad

Para el diseño de modelos de aprendizaje automático, Matlab proporciona un flujo de trabajo que nos ayuda a desarrollar y evaluar los modelos de predicción. En la Figura 8 se muestra un esquema que resume el procedimiento que se debe seguir.

Figura 8

Flujo de trabajo para el desarrollo y evaluación de modelos de aprendizaje automático en Matlab




Nota. Tomado de matlabacademy.mathworks.com/Machine Learning with Matlab.

Sin embargo, para la construcción de los modelos de predicción usando redes neuronales en este proyecto se implementó el siguiente flujo de trabajo, tanto para los modelos de predicción a partir de registros como para los modelos de integración con tomografía:

Figura 9

Flujo de trabajo aplicado para el desarrollo y evaluación de los modelos de aprendizaje automático en Matlab



Nota. Tomado de matlabacademy.mathworks.com/Machine Learning with Matlab

El preprocesamiento de los datos estuvo principalmente relacionado con la extracción de la información en archivos más fáciles de manejar para la lectura, filtro y análisis de datos, tanto para la información de registros como la de tomografía computarizada. Fue necesario filtrar cuidadosamente los sets de datos de registro y tomografía con el fin de seleccionar los valores que

coincidían a las profundidades específicas de los datos petrofísicos y de esta manera, aplicar un buen entrenamiento del modelo.

5.1.1 Datasets de Entrenamiento

Se usaron los datos del Pozo-3 para el entrenamiento de las redes neuronales, mientras que los datos del Pozo-1 y del Pozo-2 fueron usados para probar los resultados de los modelos. Se realizó de esta manera ya que, como se observa en el reporte (Tabla 3), el Pozo-3 contenía la mayor cantidad de datos petrofísicos para el entrenamiento de la red.

Para el desarrollo del modelo de predicción de porosidad a partir de registros se hicieron pruebas variando los registros usados como datos de entrada. Luego de verificar los resultados de estas pruebas, los modelos que mostraron mejores ajustes fueron los que tuvieron dos registros litológicos y dos registros petrofísicos como datos de entrada (*input dataset*). Para todos los casos se usaron datos de porosidad RCAL como datos de salida (*target output dataset*). De esta manera, se contó con los siguientes datos para el entrenamiento de la red:

Input dataset:

- GR log data
- SP log data
- Porosity log data (NPHI)
- Density log data (RHOB)

Target output dataset:

- Core porosity data (PHI RCAL)

Ahora bien, para el modelo de integración se añadieron los datos extraídos de las imágenes de tomografía (densidad aparente y factor fotoeléctrico) a los datos de entrada, obteniendo los siguientes sets de datos para entrenamiento:

Input dataset:

- GR log data
- SP log data
- Porosity log data (NPHI)
- Density log data (RHOB)
- Bulk density CT data (RHOB-CT)
- Photoelectric factor CT data (PEF-CT)

Target output dataset:

- Core porosity data (PHI RCAL)

Para los 125 datos de porosidad con los que contaba el Pozo-3 entre 3745 – 4264.5 ft, se identificaron puntualmente las profundidades en las que se encontraban estos datos y se filtraron los 125 datos de registros de los 2078 que cubrían este rango de profundidades (resolución vertical de 0.25 ft) para obtener los datos de entrada en el entrenamiento del modelo de porosidad a partir de registros (Consultar Apéndice A).

De manera similar, para los datos de porosidad con los que contaba el Pozo-3 entre 3745 – 4264.5 ft se filtraron entre 57 secciones de 3ft los 125 datos de tomografía de los 83391 que cubrían este rango de profundidades (resolución de 0.625 mm) y fueron incluidos en los datos de entrada para el entrenamiento del modelo de porosidad a partir de registros con tomografía (Consultar Apéndice B).

5.1.2 Metodología aplicada en el Modelo de Predicción de Porosidad a partir de Registros

Una vez definido el dataset para el entrenamiento del modelo se procedió a determinar la topología más adecuada de la red neuronal, con el fin de obtener un modelo que se ajuste a los datos de entrenamiento pero que también asegure buenos resultados haciendo predicciones futuras.

Matlab permite ajustar: *i)* la estructura de la red neuronal, definiendo el número de capas y el número de neuronas en cada capa; *ii)* al algoritmo de entrenamiento, entre los que se puede elegir el algoritmo de retropropagación (*backpropagation*) de Levenberg-Marquardt y el de Regularización Bayesiana; *iii)* la función de activación de las neuronas por cada capa, entre las que se encuentran la función de transferencia tangente sigmoidea hiperbólica, la función de transferencia sigmoidea logarítmica y la función de transferencia sigmoidea de Elliot; y *iv)* la división porcentual de los datos en los sets de entrenamiento, validación y prueba.

Luego de hacer pruebas modificando cada una de las características, el escenario que generó la red neuronal con mejor ajuste de datos fue el siguiente:

Tabla 4

Topología de la red neuronal para entrenar el modelo de predicción de porosidad a partir de registros

Estructura	6 capas ocultas, 10 neuronas en cada una
Algoritmo de entrenamiento	Backpropagation de Levenberg-Marquardt
Funciones de activación	Función de transferencia tangente sigmoidea hiperbólica
División sets de entrenamiento, validación y prueba	Entrenamiento: 70%, Validación; 15%, Prueba: 15%

Nota. Para la estructura de la red se hicieron variaciones aumentando y disminuyendo el número de capas, así como el número de neuronas en cada capa. Además, se probaron divisiones en los datos de entrada para el entrenamiento con conjuntos de 70%-15%-15% y 60%-20%-20% para los sets de entrenamiento, validación y prueba, respectivamente. También se probaron los resultados de los modelos definiendo diferentes algoritmos de entrenamiento y funciones de activación.

Todas estas características fueron definidas por código en un script de Matlab. El script incluye la carga del dataset de entrenamiento y el entrenamiento de la red con las características descritas anteriormente.

De acuerdo con la robustez del modelo y a la cantidad de datos usados para el entrenamiento, el programa tardará en encontrar el modelo con mayor ajuste entre los sets de entrenamiento, validación y prueba. La ventaja que ofrece el paquete de herramientas de *Machine Learning* en Matlab, es que permite correr varias veces el modelo con las características definidas hasta encontrar el mejor ajuste de la red neuronal. Cuando se ha determinado el modelo que mejor se ajusta, se pueden extraer los parámetros de la red que permitirán hacer futuras predicciones a partir de nuevos datos de entrada, sin perder el rendimiento del modelo. De esta manera se consigue desarrollar un modelo predictivo a partir del entrenamiento de una red neuronal.

El entrenamiento de este modelo mostró los siguientes resultados:

Tabla 5

Parámetros de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros en tres diferentes corridas

Run	Entrenamiento	Validación	Prueba	Total
#	R^2	R^2	R^2	R^2
1	0.868	0.734	0.826	0.835
2	0.929	0.911	0.879	0.918
3	0.736	0.814	0.512	0.717


Nota. La tabla muestra los resultados del entrenamiento de la red neuronal en cada corrida. Para la selección de un modelo con ajustes satisfactorios no sólo se tuvo en cuenta el error en los sets de entrenamiento y/o total, sino que se eligió de acuerdo con el mejor ajuste del set de validación. Por

definición, el ajuste en este conjunto de datos determina la capacidad del modelo de hacer predicciones futuras con nuevas observaciones.

En la corrida #2 el modelo mostró un buen ajuste para los conjuntos de entrenamiento, validación, prueba y total. Por esta razón, los parámetros de la red neuronal durante este entrenamiento fueron los que se eligieron para el modelo de predicción. Los resultados del entrenamiento de la red neuronal durante esta corrida fueron los siguientes:

Figura 10

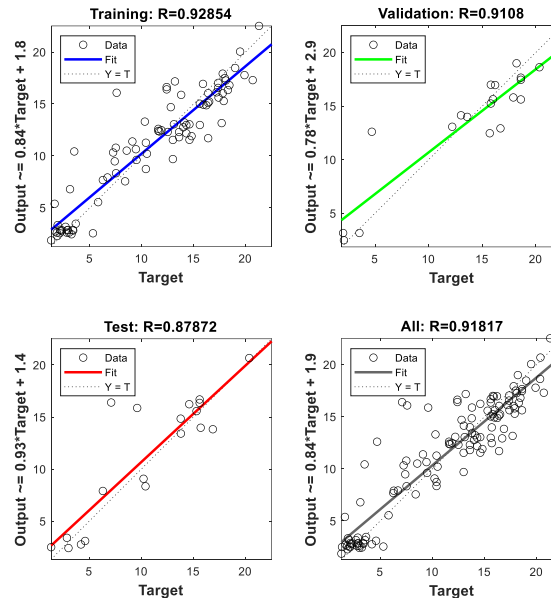
Gráfico de rendimiento (*performance plot*) del entrenamiento del modelo de predicción de porosidad a partir de registros durante la corrida #2



Nota. Como se mencionó anteriormente, Matlab usa el set de datos de validación para evitar el *over-fitting*. Las iteraciones para el ajuste del modelo a los datos de entrenamiento continúan hasta que se alcanza un mínimo en el error cuadrático medio (*MSE*, *Mean Squared Error - ECM*) del conjunto de datos para validación, y no se alcanza a disminuir en las próximas 6 épocas (iteraciones para el ajuste en los pesos de la red). En la figura se observa que a partir de la época #12 aumenta el ECM del set de validación y no se logra disminuir este error en las 6 épocas siguientes, por lo que las iteraciones terminan en la época #18.

Figura 11

Gráficos de regresión (regression plots) del entrenamiento del modelo de predicción de porosidad a partir de registros durante la corrida #2



Nota. Cada gráfico de regresión relaciona los datos estimados por el modelo (*Outputs*) con los datos de salida ingresados para el entrenamiento de la red (*Targets*). Para todos los modelos entrenados se extrajeron los parámetros de la red y se generó un código compilado en Matlab a partir de los cuales se pueden realizar predicciones futuras ingresando nuevos datos de entrada. Para conocer el código de este modelo entrenado, consultar el Apéndice E.

5.1.3 Metodología aplicada en el Modelo de Integración de Registros con Tomografía

Inicialmente, se planteó crear un modelo independiente de predicción de registros a partir de tomografía e integrarlo con el modelo de predicción de porosidad a partir de registros, con el objetivo de aumentar la resolución de los datos de registros y aprovechar el ajuste del modelo de predicción ya definido, pero no se obtuvieron buenos resultados. Esto se debe principalmente a que no se cuenta con una relación directa entre los datos de tomografía y todos los registros que

alimentan el modelo de predicción de porosidad. Además, de esta manera se propaga el error entre los modelos. Por esta razón, se decidió entrenar un solo modelo que se alimenta tanto de datos de registros como de tomografía. El reto fue diseñar un modelo que, para predicciones futuras, ajuste la resolución de los datos de registros a la resolución de los datos de tomografía. El método empleado para resolver este problema se describe más adelante.

Aprovechando los buenos resultados obtenidos con la topología definida en el modelo de predicción, se aplicaron las mismas características para el entrenamiento de la red integrando la información de tomografía:

Tabla 6

Topología de la red neuronal para entrenar el modelo de predicción de porosidad a partir de registros con tomografía

Estructura	6 capas ocultas, 10 neuronas en cada una
Algoritmo de entrenamiento	Backpropagation de Levenberg-Marquardt
Funciones de activación	Función de transferencia tangente sigmoidea hiperbólica
División sets de entrenamiento, validación y prueba	Entrenamiento: 70%, Validación; 15%, Prueba: 15%

En este modelo, con la topología anteriormente definida, fue necesario realizar un mayor número de corridas para obtener un ajuste satisfactorio en los sets de entrenamiento, validación y prueba. Los resultados se muestran a continuación:

Tabla 7

Parámetros de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros con tomografía en siete diferentes corridas

Run	Entrenamiento	Validación	Prueba	Total
#	R ²	R ²	R ²	R ²
1	0.901	0.858	0.765	0.873
2	0.983	0.794	0.970	0.957
3	0.978	0.903	0.882	0.953
4	0.959	0.963	0.952	0.955
5	0.973	0.960	0.921	0.961
6	0.936	0.923	0.670	0.903
7	0.984	0.967	0.876	0.970

Aunque se obtuvieron buenos resultados en las primeras tres corridas se decidió probar realizando más entrenamientos de la red con el fin de obtener un modelo con mejor ajuste del set de validación. En la corrida #7 se obtuvieron los mejores resultados, tanto en el set de validación como en los sets de entrenamiento y total. A continuación, se muestran los resultados del entrenamiento de la red neuronal durante esta corrida:

Figura 12

Gráfico de rendimiento del entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía durante la corrida #7


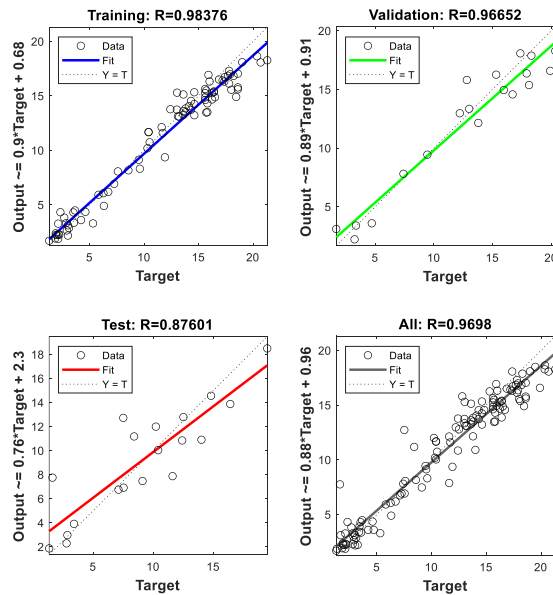


Figura 13

Gráficos de regresión del entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía durante la corrida #7



Nota. Para conocer el código compilado a partir de este modelo entrenado, consultar el Apéndice F.

Con el modelo de predicción entrenado integrando datos de registros con tomografía, se procedió a definir un método que permita incluir los datos de registros para hacer predicciones futuras, pero manteniendo la posibilidad de alimentar el modelo con la alta resolución de la información de tomografía. Para conseguir esto, la opción más viable fue aumentar la resolución de los datos de registros interpolando los valores intermedios según la resolución vertical de estos. La ventaja de aplicar este método es que los registros muestran una tendencia continua entre cada valor a pesar de la heterogeneidad. Por lo tanto, la interpolación de los datos debería mostrar los valores de la misma manera que si, en teoría, se aumentara la resolución vertical de la medición con registros. Teniendo esto en cuenta, los valores obtenidos en cada registro por interpolación deberían ser confiables para alimentar el modelo y hacer predicciones futuras.

Para entrenar un modelo a partir de redes neuronales es necesario que la cantidad de datos por cada característica (*feature*) sea la misma, tanto para los datos de entrada como los de salida. Esto implica que, para hacer predicciones futuras también debe asegurarse que el número de datos por característica sean los mismos. Por esta razón, no solo basta con interpolar los datos entre los valores de los registros, sino que se requiere que el número de datos sea el mismo que para el set de tomografía seleccionado. Para lograrlo, se cargaron los datos de tomografía de uno de los pozos en Excel y, aprovechando que la información incluye la discriminación por *cores* y por secciones (*trays*), se filtraron los datos y se identificó la cantidad de datos por sección: en total, 1463 datos por sección de 3 ft para un escaneo con resolución de 0.625 mm. Con esto, se obtiene la cantidad de datos que se deben interpolar entre cada valor de un registro con resolución vertical de 0.25 ft: 120 datos en el primer intervalo de 0.25 ft y 121 datos en el resto de los intervalos. Sin embargo, el código en Matlab está diseñado para ajustarse si la resolución vertical de los registros es

diferente (Por ejemplo 0.5 ft, la más común). Un esquema que permite entender esta distribución de datos por sección se presenta a continuación:

Figura 14

Distribución de la cantidad de datos en la interpolación para la integración de registros con tomografía


Tomografía	120	121	121	121	121	121	121	121	121	121	121	121	1463 datos
Registros	1	2	3	4	5	6	7	8	9	10	11	12	12 datos
	0.0	0.25	0.5	0.75	1.0	1.25	1.5	1.75	2.0	2.25	2.5	2.75	

Nota. El esquema ilustra la distribución de la cantidad de datos intermedios que se deben interpolar entre los valores de un registro con resolución de 0.25 ft. La suma de los datos interpolados más los datos proporcionados por el registro es equivalente al total de datos de tomografía correspondiente a una sección de 3 ft (1463 datos). Este procedimiento se repite de acuerdo con el número de secciones que se deseen evaluar en el modelo, por esta razón el método no incluye el último dato de la sección de 3 ft, ya que este estaría incluido en la siguiente.

Ahora bien, a partir de esta información se diseñó el modelo para que funcione alimentándose con secciones completas de 3 ft, con el fin de garantizar que se cumpla este requerimiento sin afectar el rendimiento del modelo. En la Figura 15 se muestran los resultados del método aplicado en un intervalo del registro GR tomado del Pozo-1.

Figura 15

Gráfico de validación del registro GR aplicando el método de interpolación



Nota. En el gráfico se observa que la interpolación de los datos mantiene la tendencia del registro con una resolución de 0.625 mm.

El método fue programado en un Script que, en conjunto con el código compilado del modelo entrenado de predicción de porosidad a partir de registros con tomografía, integra los datos de entrada y genera las predicciones de porosidad con la resolución de los datos de tomografía. Para conocer los detalles del código implementado, consultar el Apéndice I. Adicionalmente, se desarrolló una herramienta interactiva con la que se pueden cargar los datos, generar las estimaciones en una tabla de resultados, exportarlos y visualizarlos en gráficos de validación (Consultar Apéndice K).

5.2 Modelos de Predicción de Permeabilidad

Para el caso de los modelos de predicción de permeabilidad se siguió el mismo flujo de trabajo, la diferencia estuvo principalmente en los datos usados para el entrenamiento de las redes y en que fue necesario hacer un preprocesamiento en los datos para lograr el ajuste de los modelos.

5.2.1 Datasets de Entrenamiento

Nuevamente, se usaron los datos del Pozo-3 para el entrenamiento de las redes neuronales y los datos del Pozo-1 y del Pozo-2 para probar los resultados.

Ya que la mayoría de los modelos propuestos en la literatura incluyen la porosidad para la estimación de la permeabilidad, se añadió a los registros datos de porosidad para obtener mejores resultados. Sin embargo, ingresando directamente los datos de porosidad y permeabilidad, los modelos no consiguieron ajustarse a los datos de entrenamiento sin importar los cambios en la topología de la red o el número de corridas para el entrenamiento. El ajuste se consiguió procesando los datos de porosidad y permeabilidad; en este caso, aplicando logaritmo natural en ambos.

De esta manera, para el modelo de predicción de permeabilidad a partir de registros se alimentó la red con dos registros litológicos y uno resistivo como datos de entrada, mientras que se usaron datos de permeabilidad Klinkenberg como datos de salida. Por lo tanto, se contó con los siguientes datos para el entrenamiento de la red:

Input dataset:

- GR log data
- SP log data
- LLD log data
- Core porosity data (PHI RCAL)

Target output dataset:

- Klinkenberg permeability data

Igual que para el modelo integrado de porosidad, para el modelo integrado de permeabilidad se añadieron los datos extraídos de las imágenes de tomografía a los datos de entrada, obteniendo los siguientes sets de datos para entrenamiento:

Input dataset:

- GR log data
- SP log data
- LLD log data
- Bulk density CT data (RHOB-CT)
- Photoelectric factor CT data (PEF-CT)
- Core porosity data (PHI RCAL)

Target output dataset:

- Klinkenberg permeability data

Para entrenar el modelo de permeabilidad a partir de registros y el modelo integrado con información de tomografía, se usaron los datos de porosidad RCAL recolectados del Pozo-3. Sin embargo, para las pruebas y futuras estimaciones, los modelos entrenados se pueden usar en conjunto con el modelo integrado de porosidad, y así obtener un set de datos de alta resolución. De esta forma, si se quieren hacer predicciones futuras ambos modelos (el de porosidad y el de permeabilidad) se alimentarían netamente con datos de registros y tomografía. Además de que, no es fácil obtener un set de datos de porosidad con resolución vertical uniforme como en el caso de los registros.

Para obtener los datos de registros y tomografía correspondientes a las profundidades donde se encontraban los datos petrofísicos (en este caso, la permeabilidad), se aplicó el mismo

procedimiento. Una descripción de los sets de datos usados para el entrenamiento del modelo de predicción a partir de registros y del modelo integrado con información de tomografía se encuentra en los Apéndices C y D.

5.2.2 Metodología aplicada en el Modelo de Predicción de Permeabilidad a partir de Registros

Con los datasets de entrenamiento ya creados y listos para cargar, se procedió a ejecutar el código de entrenamiento de la red. Siguiendo la misma secuencia, se aplicó la misma topología usada en el modelo de predicción de porosidad:

Tabla 8

Topología de la red neuronal para entrenar el modelo de predicción de permeabilidad a partir de registros

Estructura	6 capas ocultas, 10 neuronas en cada una
Algoritmo de entrenamiento	Backpropagation de Levenberg-Marquardt
Funciones de activación	Función de transferencia tangente sigmoidea hiperbólica
División sets de entrenamiento, validación y prueba	Entrenamiento: 70%, Validación; 15%, Prueba: 15%

Luego de realizar cuatro corridas para el entrenamiento del modelo, los resultados fueron los siguientes:

Tabla 9

Parámetros de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros en cuatro diferentes corridas

Run	Entrenamiento	Validación	Prueba	Total
#	R ²	R ²	R ²	R ²
1	0.966	0.964	0.968	0.963
2	0.921	0.982	0.887	0.922
3	0.926	0.961	0.952	0.936
4	0.980	0.980	0.980	0.979

El mejor ajuste del modelo se consiguió en la corrida #4. Los resultados de este entrenamiento fueron los siguientes:

Figura 16

Gráfico de rendimiento del entrenamiento del modelo de predicción de permeabilidad a partir de registros durante la corrida #4


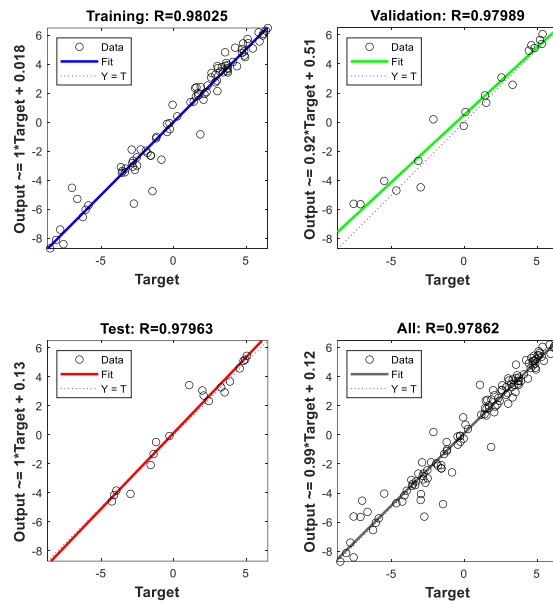


Figura 17

Gráficos de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros durante la corrida #4



Nota. Para conocer el código compilado a partir de este modelo entrenado, consultar el Apéndice G.

5.2.3 Metodología aplicada en el Modelo de Integración de Registros con Tomografía

Con el modelo integrado de permeabilidad también se obtuvieron buenos resultados aplicando la misma topología usada en el entrenamiento de los modelos anteriores. Sin embargo, el rendimiento en el ajuste del modelo integrando la información de tomografía no mejoró de la misma manera como cuando se integraron al modelo de porosidad. Por esto, se ajustó la estructura de la red neuronal en este caso aumentando el número de neuronas en las primeras tres capas. La topología red que se usó para el entrenamiento fue la siguiente:

Tabla 10

Topología de la red neuronal para entrenar el modelo de predicción de permeabilidad a partir de registros con tomografía

Estructura	6 capas ocultas, 20 neuronas en las primeras 3 capas y 10 neuronas en las últimas 3 capas
Algoritmo de entrenamiento	Backpropagation de Levenberg-Marquardt
Funciones de activación	Función de transferencia tangente sigmoidea hiperbólica
División sets de entrenamiento, validación y prueba	Entrenamiento: 70%, Validación; 15%, Prueba: 15%

Como en el caso del modelo integrado de porosidad, para obtener un ajuste satisfactorio en los sets de entrenamiento, validación y prueba se realizó un mayor número de corridas en el entrenamiento. Los resultados fueron los siguientes:

Tabla 11

Parámetros de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros con tomografía en siete diferentes corridas

Run	Entrenamiento	Validación	Prueba	Total
#	R ²	R ²	R ²	R ²
1	0.981	0.954	0.841	0.952
2	0.946	0.960	0.880	0.938
3	0.990	0.982	0.939	0.972
4	0.971	0.788	0.952	0.945
5	0.937	0.838	0.909	0.911
6	0.999	0.946	0.899	0.973
7	0.967	0.965	0.969	0.967

Aunque en la corrida #3 el entrenamiento mostró mejores resultados, durante la validación con los datos del Pozo-1 y el Pozo-2 el modelo que mejor se ajustó fue obtenido en el entrenamiento de la corrida #7. Los resultados de este entrenamiento se presentan a continuación:

Figura 18

Gráfico de rendimiento del entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía durante la corrida #7


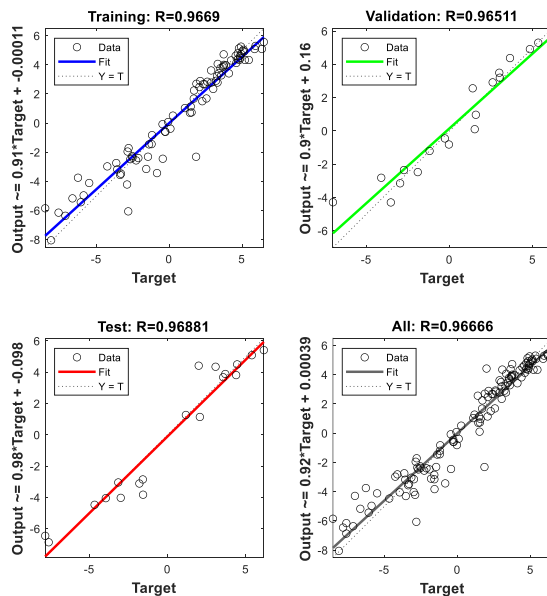


Figura 19

Gráficos de regresión del entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía durante la corrida #7



Nota. Para conocer el código compilado a partir de este modelo entrenado, consultar el Apéndice H.

En conjunto con el método de integración se generó un Script para diseñar el modelo de predicción de permeabilidad a partir de registros integrado con tomografía (Consultar Apéndice J) y al igual que para el modelo de porosidad, se compiló una herramienta interactiva que permite cargar los datos, validar los resultados mediante gráficos y exportarlos en un archivo Excel (Consultar Apéndice L).

6. Análisis de Resultados

Se usaron intervalos del Pozo-1 y del Pozo-2 para la evaluación de los modelos, pero también se muestran los resultados evaluando los modelos sobre un intervalo específico del Pozo-3. Para esto, se seleccionaron secciones completas de 3 ft de un *core* escaneado para cada pozo. El dataset de cada pozo utilizado para la evaluación de los modelos se describe a continuación:

Tabla 12

Resumen del set de datos del Pozo-1 para la evaluación de los modelos de predicción integrados con tomografía

Core	Sección (Tray)	Tope (ft)	Base (ft)	#Registros	#Tomografía
C008	T001	4589	4592	12	1463
C008	T002	4592	4595	12	1463
C008	T003	4595	4598	12	1463
C008	T004	4598	4601	12	1463
C008	T005	4601	4604	12	1463
C008	T006	4604	4607	12	1463
C008	T007	4607	4610	12	1463
C008	T008	4610	4613	12	1463
C008	T009	4613	4616	12	1463

Tabla 13

Resumen del set de datos del Pozo-2 para la evaluación de los modelos de predicción integrados con tomografía

Core	Sección (Tray)	Tope (ft)	Base (ft)	#Registros	#Tomografía
C003	T001	4746	4749	12	1463
C003	T002	4749	4752	12	1463
C003	T003	4752	4755	12	1463
C003	T004	4755	4758	12	1463
C003	T005	4758	4761	12	1463
C003	T006	4761	4764	12	1463
C003	T007	4764	4767	12	1463

Tabla 14

Resumen del set de datos del Pozo-3 para la evaluación de los modelos de predicción integrados con tomografía

Core	Sección (Tray)	Tope (ft)	Base (ft)	#Registros	#Tomografía
C005	T001	4073	4076	12	1463
C005	T002	4076	4079	12	1463
C005	T003	4079	4082	12	1463
C005	T004	4082	4085	12	1463
C005	T005	4085	4088	12	1463
C005	T006	4088	4091	12	1463
C005	T007	4091	4094	12	1463
C005	T008	4094	4097	12	1463
C005	T009	4097	4100	12	1463
C005	T010	4100	4103	12	1463

C005 T011 4103 4106 12 1463


6.1 Modelos de Predicción de Porosidad

Antes de validar los modelos de predicción en los Pozos 1 y 2 con el método de integración, se usaron los datos de porosidad RCAL con los que contaban estos pozos para evaluar su rendimiento mediante gráficos de regresión, en los que se comparan los datos reales con los datos estimados a partir de la información de registros y tomografía (estos datos de entrada fueron seleccionados a cada profundidad específica en la que se encontraban los datos de porosidad y alimentados en los modelos entrenados que se muestran en los Apéndices E y F).

Los gráficos de regresión mostraron los siguientes resultados:

Figura 20

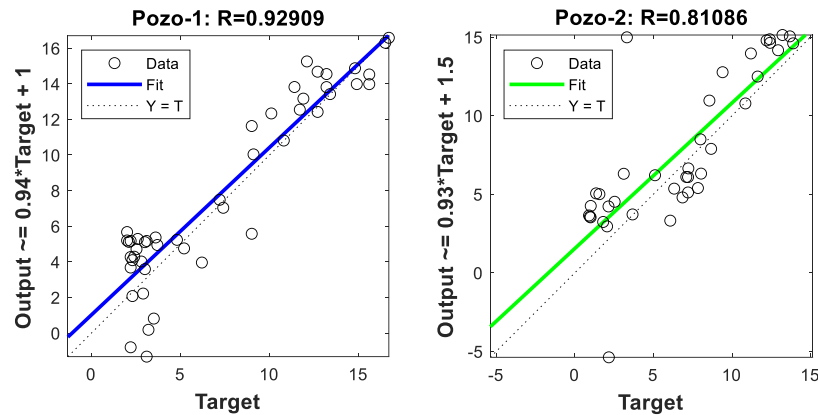
Gráficos de regresión del modelo de predicción de porosidad a partir de registros evaluado sobre los Pozos 1 y 2



Nota. Los gráficos de regresión muestran la validación del modelo comparando los datos de porosidad reales de cada pozo con los estimados por el modelo.

Figura 21

Gráficos de regresión del modelo de predicción de porosidad a partir de registros integrado con tomografía evaluado sobre los Pozos 1 y 2

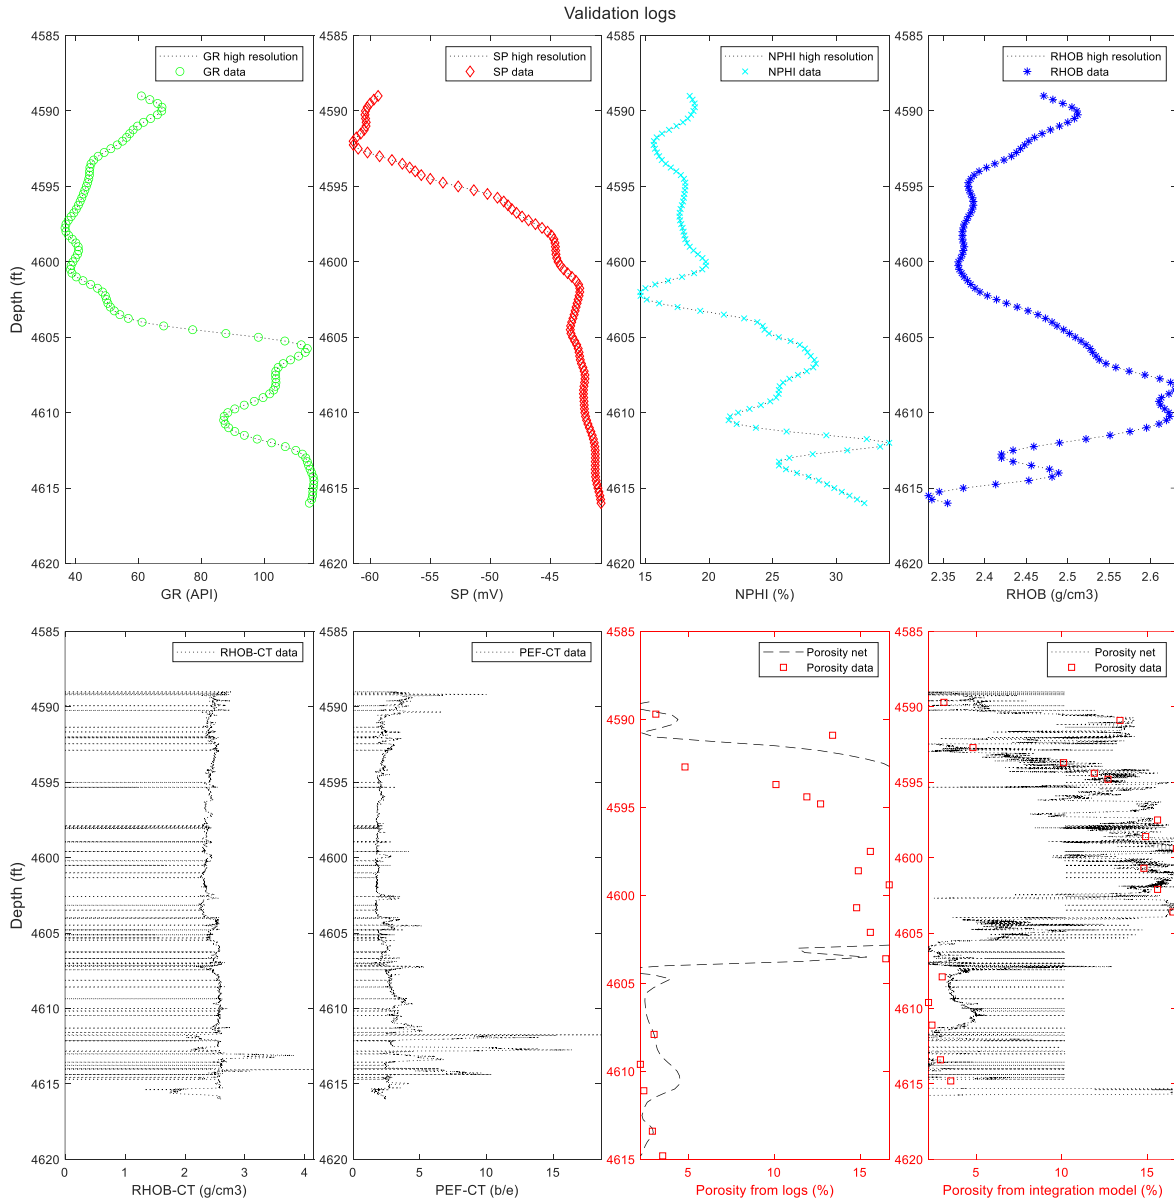


En las Figuras 20 y 21 se observa que el modelo de porosidad integrado con tomografía muestra mejores resultados comparado con el modelo alimentado sólo con datos de registros. Esta es una característica de las redes neuronales, las cuales mejoran su rendimiento al aumentar el número de características con las que se entrena.

Los resultados evidenciados en los gráficos de regresión también se pueden apreciar en las curvas generadas con los valores de porosidad estimados por cada modelo y alimentados con los sets de validación que se muestran en las Tablas 12, 13 y 14. Estos valores estimados con la resolución de los datos de tomografía se compararon con los datos de porosidad RCAL de cada pozo.

Figura 22

Validación de los modelos de predicción de porosidad con dataset del Pozo-1

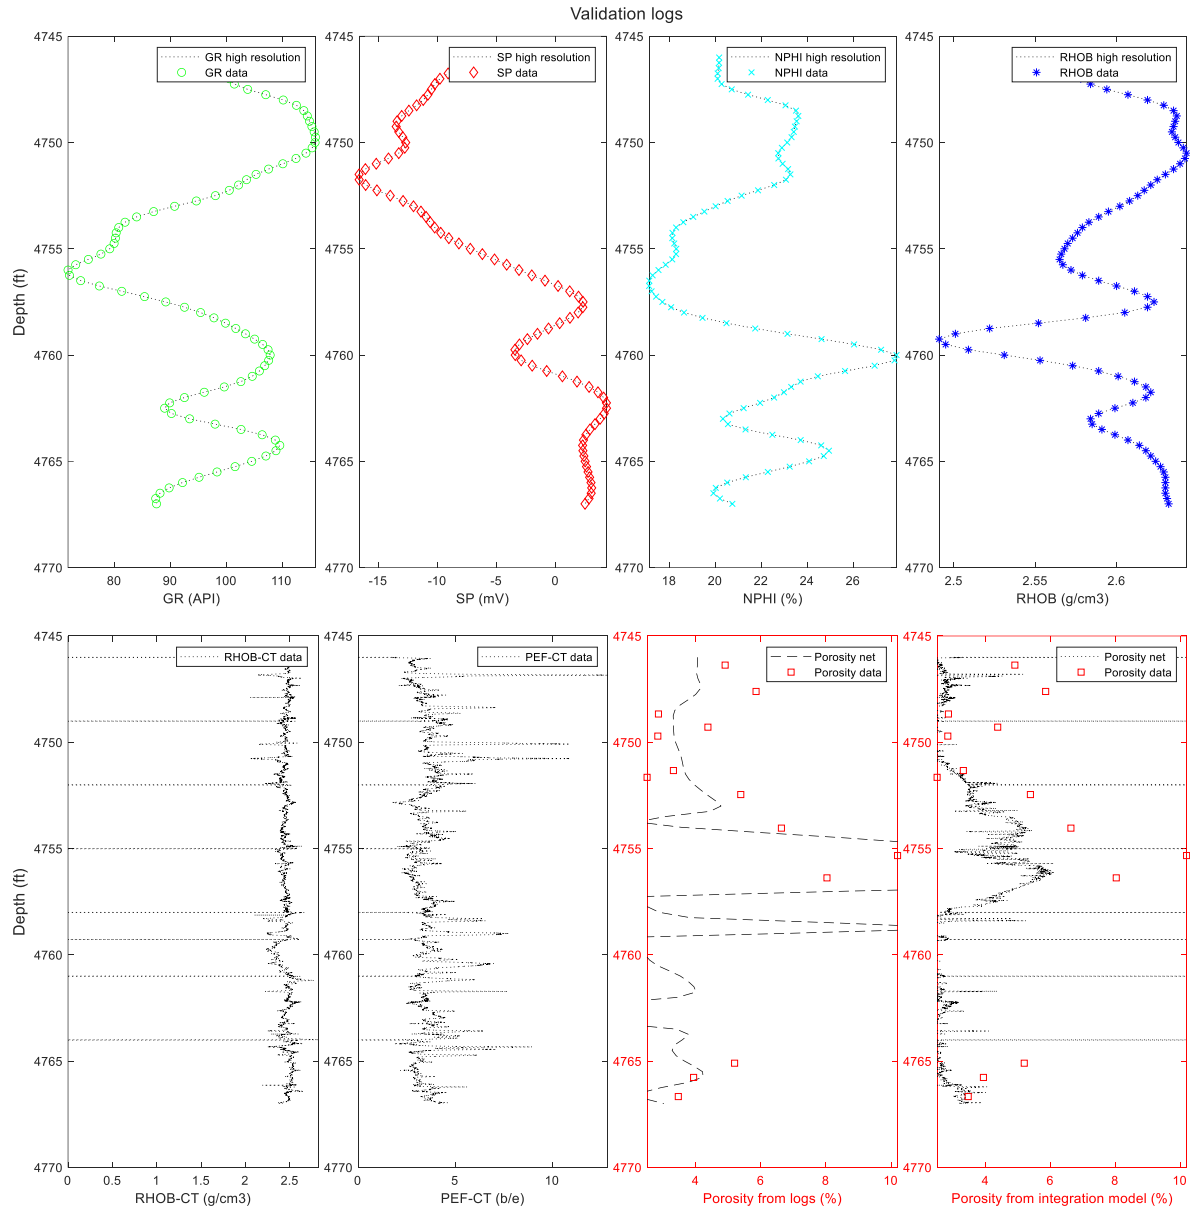


Nota 1. Los gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de porosidad con dataset del Pozo-1: el primero estima la porosidad sólo a partir de registros, el segundo es el modelo que integra registros con la información de tomografía.

Nota 2. En las Figuras 22, 23 y 24, de izquierda a derecha y de arriba hacia abajo: 1) Curva de los datos del registro GR y curva de los valores interpolados a la resolución de la información de tomografía (*GR high resolution*), 2) Curva de los datos del registro SP y curva del registro a alta resolución, 3) Curva de los datos del registro NPHI y curva del registro a alta resolución, 4) Curva de los datos del registro RHOB y curva del registro a alta resolución, 5) Curva de los datos de RHOB extraídos de las imágenes de tomografía para las secciones escaneadas, 6) Curva de los datos de PEF extraídos de las imágenes de tomografía para las secciones escaneadas, 7) Datos de porosidad RCAL del pozo en el intervalo especificado y datos de porosidad estimados por el modelo alimentado sólo con datos de registros, y 8) Datos de porosidad RCAL del pozo en el intervalo y datos de porosidad estimados por el modelo integrando la información de tomografía.

Figura 23

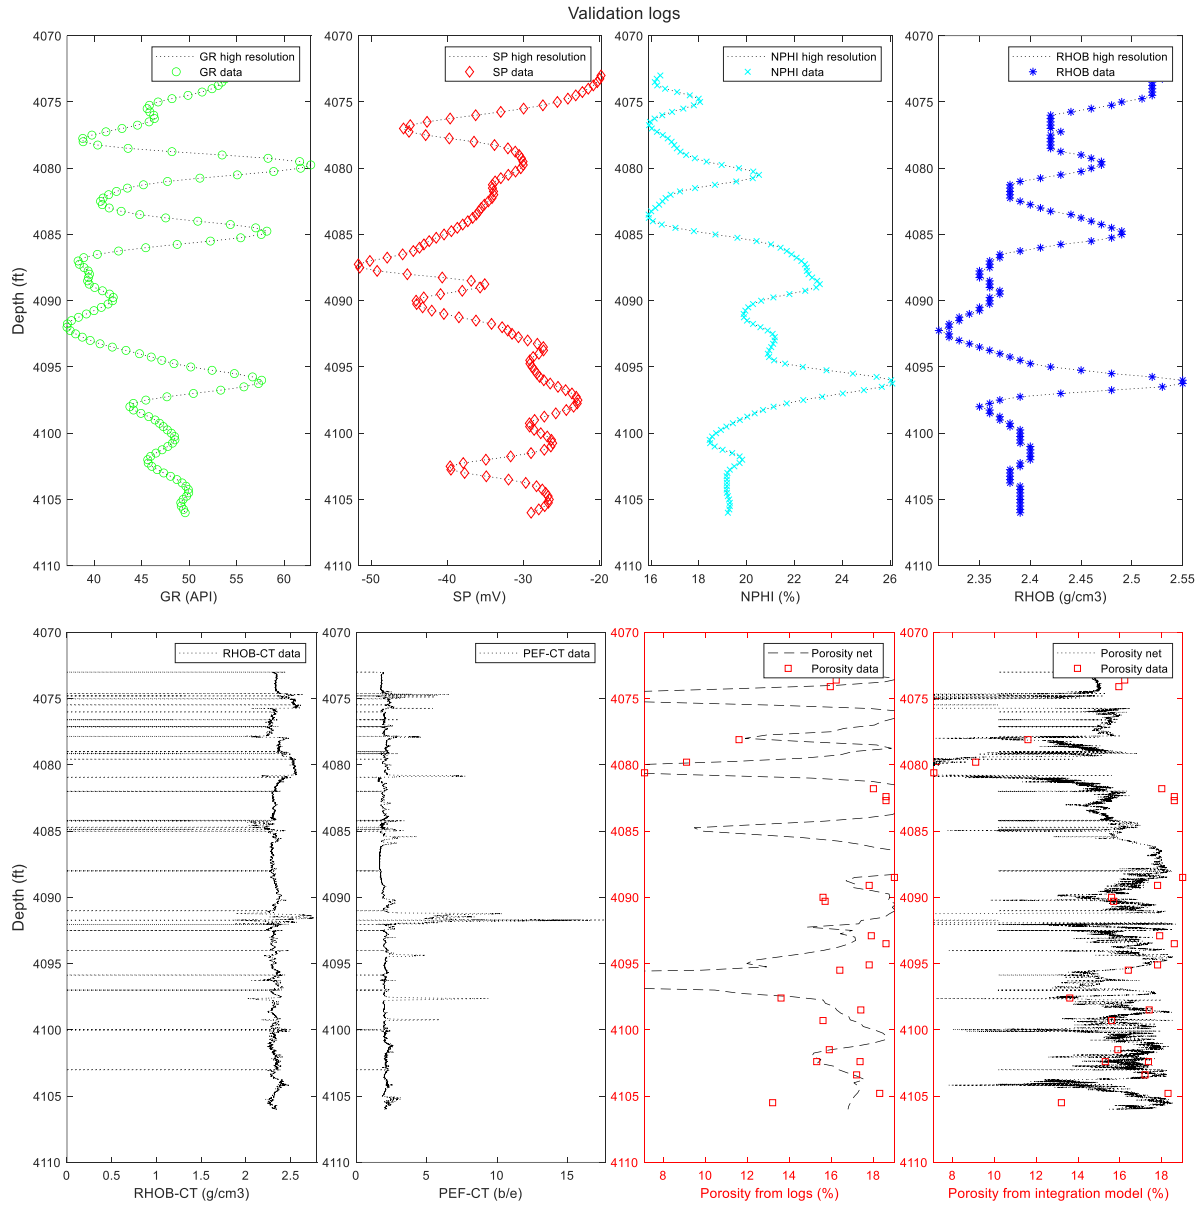
Validación de los modelos de predicción de porosidad con dataset del Pozo-2



Nota. Gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de porosidad con dataset del Pozo-2: el primero estima la porosidad sólo a partir de registros, el segundo es el modelo que integra registros con la información de tomografía.

Figura 24

Validación de los modelos de predicción de porosidad con dataset del Pozo-3



Nota. Gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de porosidad con dataset del Pozo-3: el primero estima la porosidad sólo a partir de registros, el segundo es el modelo que integra registros con la información de tomografía.

Las curvas de los modelos de predicción de porosidad usando sólo datos de registro muestran un buen ajuste, pero en los modelos integrados con tomografía se evidencia un ajuste más acertado de los datos estimados.

6.2 Modelos de Predicción de Permeabilidad

Con los modelos de permeabilidad se aplicó la metodología anterior para validar el rendimiento de los modelos mediante gráficos de regresión. Los datos de entrada fueron seleccionados a cada profundidad específica y fueron alimentados en los modelos entrenados que se muestran en los Apéndices G y H. Los resultados se presentan a continuación:

Figura 25

Gráficos de regresión del modelo de predicción de permeabilidad a partir de registros evaluado sobre los Pozos 1 y 2

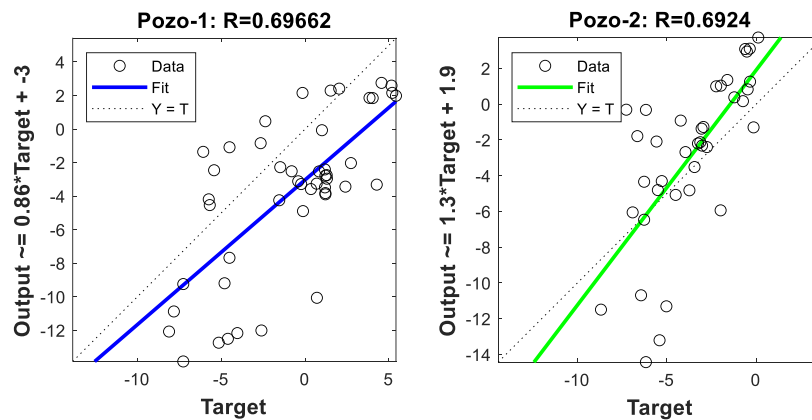
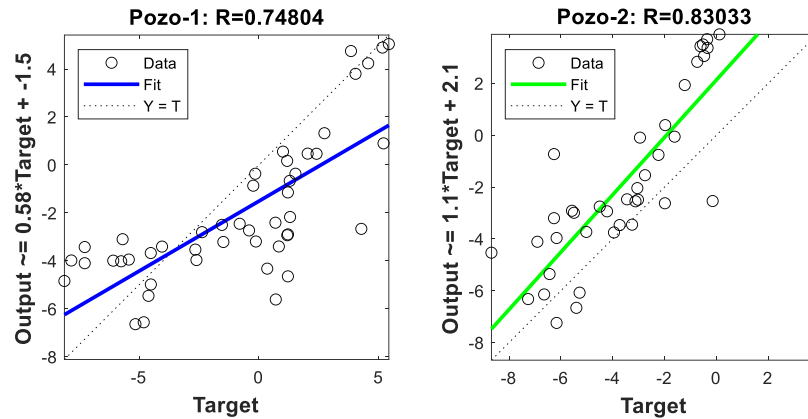


Figura 26

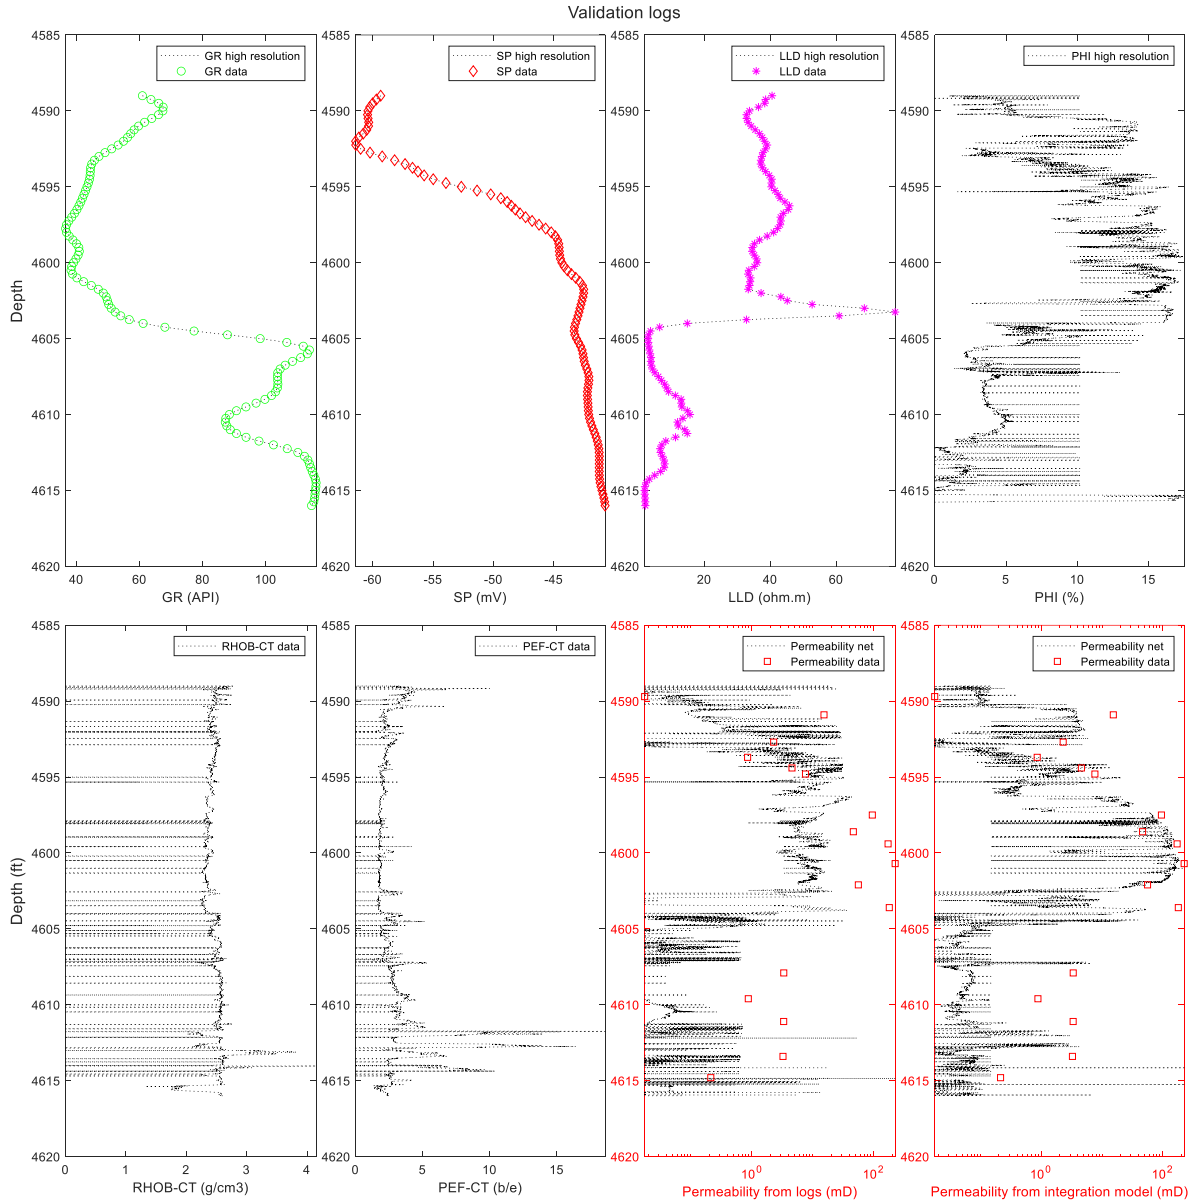
Gráficos de regresión del modelo de predicción de permeabilidad a partir de registros integrado con tomografía evaluado sobre los Pozos 1 y 2



Nuevamente, en las Figuras 25 y 26 se evidencia que el rendimiento del modelo de predicción de permeabilidad también mejora al integrar la información de tomografía. La prueba de los modelos con los sets de validación de los Pozos 1, 2 y 3 se muestra a continuación:

Figura 27

Validación de los modelos de predicción de permeabilidad con dataset del Pozo-1

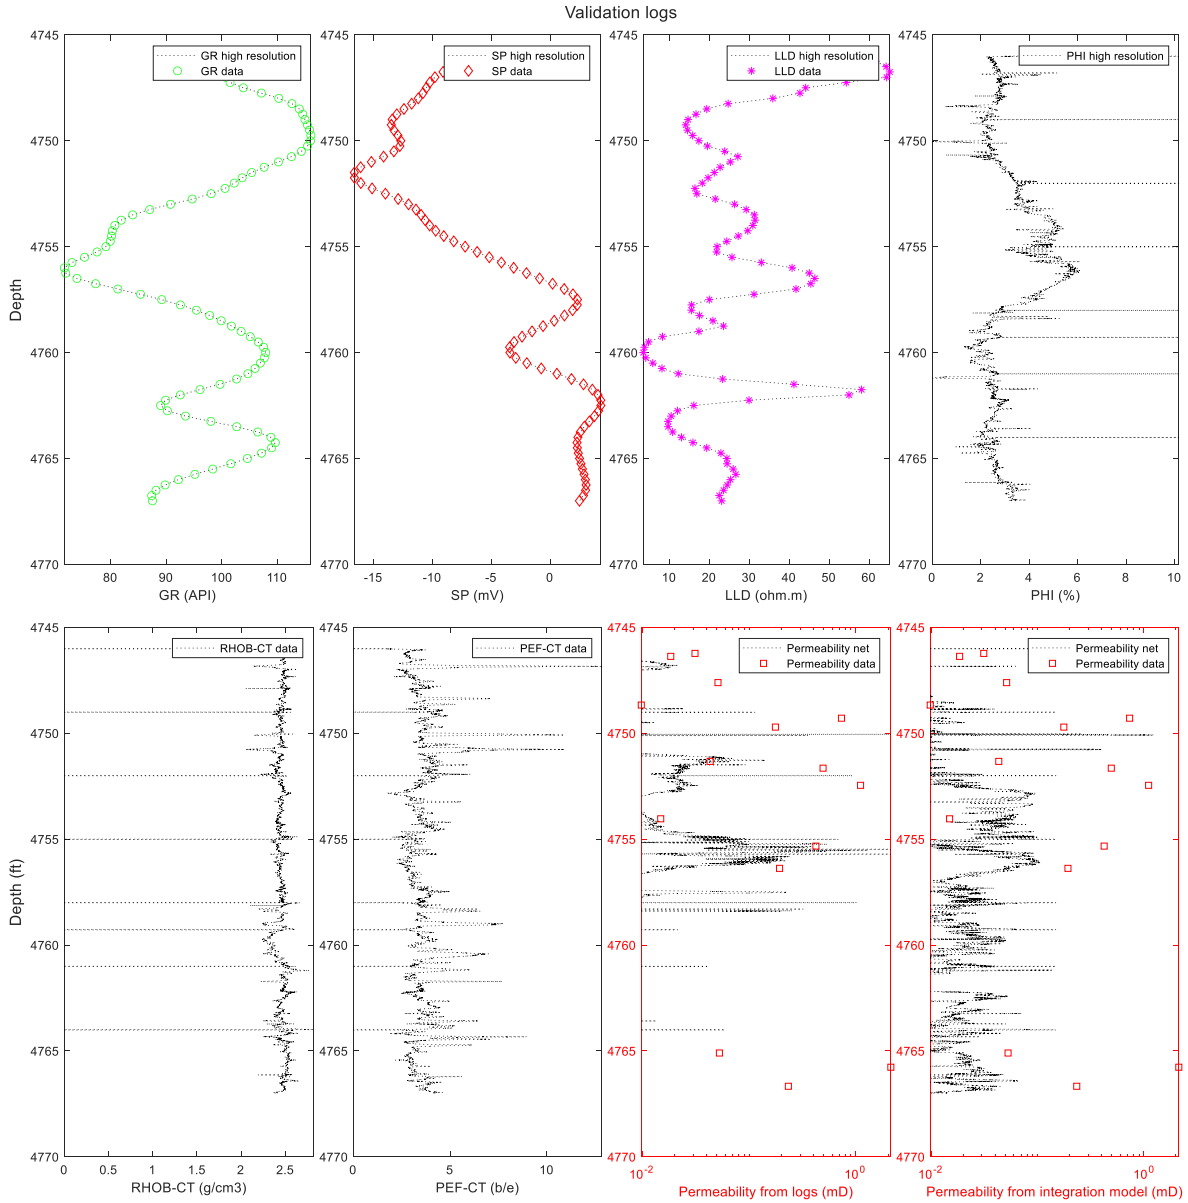


Nota 1. Los gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de permeabilidad con dataset del Pozo-1: el primero estima la permeabilidad usando sólo datos de registros, el segundo es el modelo que integra registros con la información de tomografía.

Nota 2. En las Figuras 27, 28 y 29, de izquierda a derecha y de arriba hacia abajo: 1) Curva de los datos del registro GR y curva de los valores interpolados a la resolución de la información de tomografía (*GR high resolution*), 2) Curva de los datos del registro SP y curva del registro a alta resolución, 3) Curva de los datos del registro LLD y curva del registro a alta resolución, 4) Curva de los datos de RHOB extraídos de las imágenes de tomografía para las secciones escaneadas, 5) Curva de los datos de PEF extraídos de las imágenes de tomografía para las secciones escaneadas, 6) Datos de permeabilidad Klinkenberg del pozo en el intervalo especificado y datos de permeabilidad estimados por el modelo alimentado sólo con datos de registros, y 7) Datos de permeabilidad Klinkenberg del pozo en el intervalo y datos de permeabilidad estimados por el modelo integrando la información de tomografía.

Figura 28

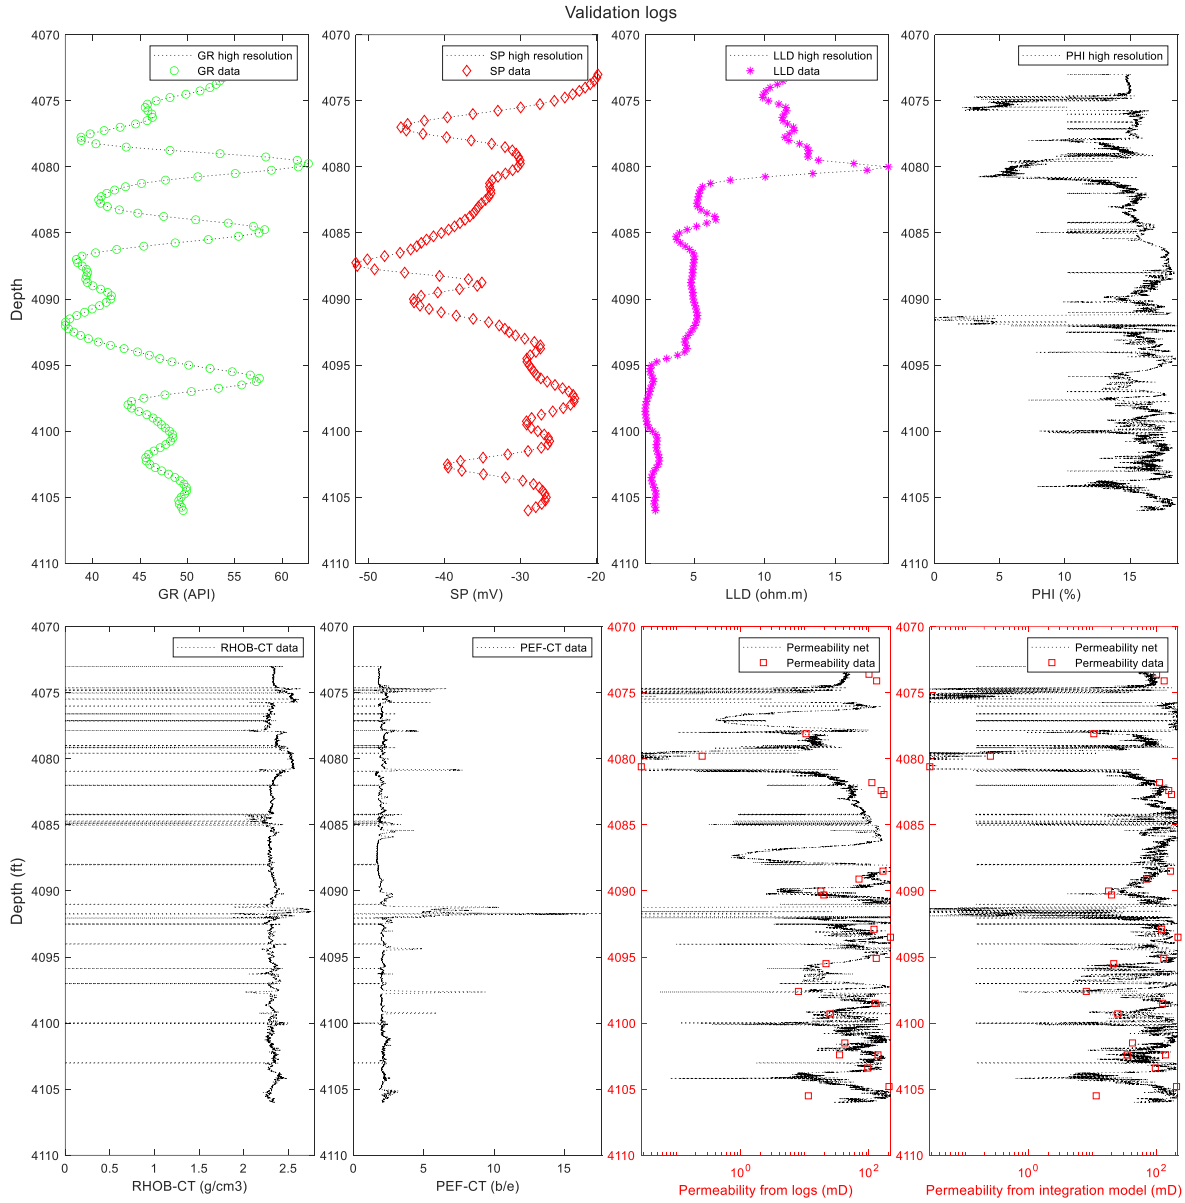
Validación de los modelos de predicción de permeabilidad con dataset del Pozo-2



Nota. Gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de permeabilidad con dataset del Pozo-2: el primero estima la permeabilidad sólo a partir de registros, el segundo es el modelo que integra registros con la información de tomografía.

Figura 29

Validación de los modelos de predicción de permeabilidad con dataset del Pozo-3



Nota. Gráficos marcados en rojo muestran los resultados en la validación de los modelos de predicción de permeabilidad con dataset del Pozo-3: el primero estima la permeabilidad usando sólo datos de registros, el segundo integra registros con la información de tomografía.

7. Conclusiones

Se generó un modelo de regresión *feed-forward network* basado en arquitectura PMC que predice porosidad y otro que estima permeabilidad a partir de la integración de datos entre registros e información de tomografía. La herramienta *Machine Learning* de Matlab facilitó la aplicación de las redes neuronales para entrenar los modelos, permitiendo evaluar rápidamente su rendimiento y ajustar la topología de la red para conseguir mejores resultados predictivos.

Los modelos de predicción integrados con tomografía mostraron un mejor ajuste en los gráficos de validación, tanto para el modelo de porosidad como el de permeabilidad. Además, los resultados que se obtuvieron en los gráficos de validación fueron compatibles con la evaluación previa que se hizo de cada modelo mediante coeficientes de determinación.

El rendimiento de los modelos integrando la información de tomografía mejoró en su ajuste con los sets de entrenamiento, validación y prueba, gracias a que se usó un mayor número de características relacionadas con los datos de salida durante el entrenamiento, a pesar de que no se tuvo disponible una mayor cantidad de muestras.

A partir de los métodos y la aplicación de los modelos generados, se obtuvo una buena integración entre los registros y la información de tomografía, un buen ajuste entre los datos estimados y los datos de laboratorio, y como resultado una herramienta que permite realizar estimaciones de propiedades petrofísicas básicas a una muy alta resolución.

8. Recomendaciones

Se recomienda implementar un método que permita validar los datos de entrada para hacer nuevas predicciones a partir de los modelos entrenados, especialmente los datos de tomografía. Los modelos generados en este estudio se basan en que los datos extraídos de imágenes de tomografía deben tener una resolución de 0.625 mm y un total de 1463 datos por sección escaneada de 3 ft.

Se puede mejorar el ajuste del modelo predictivo de permeabilidad integrando la aplicación de un método para definir unidades de flujo, a través del modelo de Winland r35 o FZI.

La integración de registros directamente con imágenes de tomografía para predecir propiedades petrofísicas también puede aplicarse integrando modelos de aprendizaje profundo (*Deep Learning*), mediante el entrenamiento de Redes Neuronales Convolucionales (*RNC*).

Referencias Bibliográficas

- Abreu, C. (2015). Porosity estimate and classification using geophysical well logs applied to the Albian carbonates of Campos Basin. Master Thesis, UENF, Macae-RJ, 100p.
- Carrasquilla, A., Abreu, C., Almeida, P., & Tavares, F. (2017). Relating laboratory and geophysical well log petrophysical properties in carbonate reservoirs of Southeast Brazil. SBGf – Sociedade Brasileira de Geofísica.
- <https://doi.org/10.1190/sbgf2017-160>
- Guiza, A. (2021). Definición de unidades de flujo por medio de información de pozo integrada con información de tomografía axial computarizada de rayos-x (TAC) [Tesis de pregrado]. Universidad Industrial de Santander.
- Isasi Viñuela, P., Galván León, I. M. (2004). Redes Neuronales Artificiales. Un enfoque práctico. Pearson Educación, S. A., Madrid.
- Morris, E. (2021). Predicción de Propiedades Petrofísicas Básicas a partir de Información de Tomografía usando un Modelo de Aprendizaje Profundo [Tesis de pregrado]. Universidad Industrial de Santander.
- Ortiz Meneses, A., Plata Chaves, J.M., Herrera Otero, E. & Santos Santos, N. (2015). Caracterización estática de Rocas por medio de Tomografía Computarizada de Rayos-X TAC. Revista Fuentes: El Reventón Energético (pp. 57-63).
- <https://doi.org/10.18273/revfue.v13n1-2015005>

- Ortiz Meneses, A., Herrera, E., Santos Santos, N. (2020). Porosity prediction from X-ray computed tomography logs (RHOB and PEF) using Artificial Neural Networks (ANN). *Boletín de Geología*, 42(3), 141-149.
- <https://doi.org/10.18273/revbol.v42n3-2020006>
- Pittman, E. (1992). Relationship of Porosity and Permeability to Various Parameters Derived from Mercury Injection-Capillary Pressure Curves for Sandstone. *The American Association of Petroleum Geologists Bulletin* (pp. 191-198).
- <https://doi.org/10.1306/BDF87A4-1718-11D7-8645000102C1865D>
- Salas, R. (2015). *Redes Neuronales Artificiales*. Departamento de Computación. Universidad de Valparaíso.
- Siddiqui, S. & Khamees, A. (2004). Dual-Energy CT-Scanning Applications in Rock Characterization. *SPE* (pp. 1-9).
- <https://doi.org/10.2118/90520-MS>
- Tellez, W. & Villarreal, R. (2008). Determinación de potenciales de producción a partir de registros de pozo. Aplicación Campo Colorado [Tesis de pregrado]. Universidad Industrial de Santander.
- Vinegar, H. & Kehl Jr., R.P. (1988). *User Guide for Computer Tomography Color Graphics System - CATPIX*. Shell Bellaire Research Center, Houston, TX (p. 85).
- Wellington, S. & Vinegar, H. (1987). X-Ray Computerized Tomography. *Journal of Petroleum Technology* (p. 885).

Wyllie, M.R.J., Gregory, A.R. & Gardner, L.W. (1956). Elastic wave velocities in heterogeneous and porous media. *Geophysics*, 21 (1), 41-70.

Apéndices

Apéndice A. Dataset Pozo-3 para el entrenamiento del modelo de predicción de porosidad a partir de registros

Input dataset				Target output dataset
GR	SP	NPHI	RHOB	ϕ
API	mV	%	g/cm ³	%
87.44	-27.36	32.6	2.34	1.9
72.42	-26.68	18.92	2.54	3.642
109.51	-18.19	33.29	2.51	2.1
106.42	-18.25	31.64	2.54	2.2
100.08	-18.56	31.56	2.57	2.893
90.77	-18.95	29.83	2.6	3.4
79.67	-16.18	27.26	2.69	2.999
100.43	-22.46	31.05	2.49	5.3
93.22	-22.72	30.2	2.57	4.2
86.07	-24.5	29.33	2.67	2.305
96.48	-27.9	32.43	2.59	1.876
95.76	-27.73	35.08	2.58	3
100.73	-17.42	32.32	2.44	1.671
96.84	-23.35	31.45	2.56	2.1
95.26	-19.19	30.77	2.58	3.357
90.03	-20.26	26.62	2.61	4.6
86.01	-23.93	23.89	2.61	5.8
72.38	-27.09	19.54	2.68	9.5
70.4	-24.35	20.97	2.66	11.7
71.26	-26.44	20.7	2.6	10.5
71.58	-27.92	20.07	2.57	10.4
71.84	-28.93	20.27	2.55	8.4

57.33	-32.05	19.07	2.51	6.255
57.61	-32.95	19.42	2.52	3.5
75.19	-34.9	23.38	2.68	12.5
70.64	-33.3	22.45	2.66	13.6
68.78	-34.4	21.87	2.61	13
65.41	-36.99	21.56	2.53	13.6
59.49	-41.01	20.44	2.48	12.8
50.4	-43.95	19.19	2.45	13.018
45.36	-44.53	18.64	2.45	10.3
43.39	-50.54	18.17	2.46	13.1
43.29	-58.39	18.33	2.47	11.6
44.74	-51.29	18.75	2.47	12.2
46.93	-38.35	18.86	2.46	13
46.94	-43.61	18.34	2.46	13.8
47.88	-48.52	17.76	2.47	14.596
49.6	-48.1	17.46	2.48	14.3
43.13	-49.56	17.34	2.47	14
42.73	-48.82	17.6	2.46	16.7
43.87	-46.9	17.6	2.44	14.1
38.41	-44.44	19.9	2.41	13.778
40.17	-44.07	20.37	2.39	17.9
36.93	-47.04	19.55	2.39	12.404
36.23	-47.36	19.42	2.39	16.4
37.6	-41.49	21.02	2.41	1.612
37.49	-41	20.62	2.4	1.274
51.55	-38.71	18.02	2.45	3.092
97.23	-14.07	25.14	2.53	2.849
98.91	-12.76	27.02	2.54	3.544
98.73	-12.69	27.73	2.53	2.023
53.41	-20.34	16.16	2.52	16.228
52.38	-21.52	16.59	2.52	15.947

38.81	-36.51	16.86	2.42	11.6
62.77	-30.05	18.95	2.47	9.1
55.04	-32.01	20.51	2.43	7.1
42.32	-33.95	17.21	2.38	18
40.64	-34.63	16.48	2.39	18.6
40.83	-35.15	16.34	2.4	18.6
39.28	-36.88	22.94	2.36	19
40.02	-35.71	22.9	2.36	17.8
41.91	-44.11	20.6	2.36	15.6
41.43	-44.03	20.26	2.36	15.7
39.55	-29.47	21.16	2.33	17.9
41.88	-27.41	21.02	2.35	18.6
50.14	-28.89	22.34	2.42	17.8
54.73	-28.26	24.43	2.48	16.4
45.41	-22.88	22.36	2.37	13.6
44.89	-25.78	20.33	2.36	17.4
46.85	-29.24	19.42	2.38	15.6
46.47	-29.03	19.39	2.4	15.9
46.03	-39.64	19.48	2.39	15.3
48.68	-31.98	19.17	2.38	17.364
49.7	-26.79	19.21	2.39	17.2
49.14	-27.23	19.29	2.39	18.3
49.15	-31.98	19	2.39	13.2
46.53	-38.78	19.23	2.41	17.7
47.75	-30.26	19.09	2.41	18.1
45.85	-26.61	18.92	2.4	16.2
46.87	-26.62	18.7	2.39	18.446
46.1	-27.62	18.7	2.39	15.8
42.57	-26.92	19.1	2.37	17.354
43.6	-27.46	19.33	2.35	14.6
48.63	-28.93	19.88	2.38	15.6

51.78	-29.16	20.28	2.37	16.5
52.45	-29.85	20.34	2.38	16
51.42	-34.28	20.42	2.37	20.692
51.15	-37.34	20.3	2.35	18.2
51.48	-39.07	20.45	2.35	19.476
51.7	-42.83	21.07	2.36	20.368
50.02	-45.44	22.31	2.39	21.3
51.3	-44.54	22.15	2.44	19.9
51.17	-37.89	22.58	2.4	20.336
44.56	-26.57	23.08	2.33	15.8
44.32	-25.06	23.2	2.32	16.868
45.64	-24.6	22.77	2.33	15.6
46.07	-24.4	22.55	2.33	15.7
44.62	-23.47	23.05	2.33	11.9
45.75	-23.48	23.1	2.32	7.5
48.6	-23.57	23.04	2.37	4.7
49.8	-25.12	22.34	2.45	9.6
49.91	-25.3	21.66	2.45	7.584
73	-34.21	18.73	2.52	8.552
73.38	-33.82	19.17	2.53	7.242
71.82	-37.35	19.37	2.58	7.525
68.43	-38.36	18.96	2.61	6.7
66.86	-38.23	18.71	2.62	6.3
64.73	-35.63	18.02	2.56	10.4
61.27	-34.79	18.41	2.54	7.4
57.79	-38.82	18.8	2.54	9.436
59.86	-41.69	17.03	2.51	10.209
61.16	-37.59	17.12	2.49	10.4
60.68	-37.26	17.24	2.49	14.6
60.66	-36.97	17.13	2.49	14.8
60.25	-36.56	17.31	2.49	14.3

58.82	-35.57	17.95	2.49	16.4
44.52	-37.43	19.37	2.4	13.8
42.98	-34.16	19.13	2.39	12.4
113.85	-24.17	36.36	2.63	2.782
116.64	-22.24	36.48	2.6	3.234
114.18	-17.66	34.79	2.54	1.335
105.97	-16.91	34.53	2.54	1.821
103.57	-15.99	32.63	2.57	2.128
91.5	-18.24	30.78	2.6	2.828
93.34	-20.55	28.03	2.55	2.659

Apéndice B. Dataset Pozo-3 para el entrenamiento del modelo de predicción de porosidad a partir de registros integrado con tomografía

Input dataset						Target output dataset
GR	SP	NPHI	RHOB	RHOB-CT	PEF-CT	ϕ
API	mV	%	g/cm ³	g/cm ³	b/e	%
87.44	-27.36	32.6	2.34	2.541649	2.681743	1.9
72.42	-26.68	18.92	2.54	2.571389	2.458046	3.642
109.51	-18.19	33.29	2.51	2.306487	6.472374	2.1
106.42	-18.25	31.64	2.54	2.330768	5.792621	2.2
100.08	-18.56	31.56	2.57	2.551033	2.722564	2.893
90.77	-18.95	29.83	2.6	2.321836	4.164345	3.4
79.67	-16.18	27.26	2.69	2.172759	5.929769	2.999
100.43	-22.46	31.05	2.49	2.5393	2.670922	5.3
93.22	-22.72	30.2	2.57	2.385941	4.335287	4.2
86.07	-24.5	29.33	2.67	2.368941	3.95905	2.305
96.48	-27.9	32.43	2.59	2.531987	2.569074	1.876
95.76	-27.73	35.08	2.58	2.515693	2.500312	3
100.73	-17.42	32.32	2.44	2.58102	2.39188	1.671

96.84	-23.35	31.45	2.56	2.243722	4.988967	2.1
95.26	-19.19	30.77	2.58	2.286384	5.355557	3.357
90.03	-20.26	26.62	2.61	2.394074	4.149707	4.6
86.01	-23.93	23.89	2.61	2.524912	2.37514	5.8
72.38	-27.09	19.54	2.68	2.473613	2.172127	9.5
70.4	-24.35	20.97	2.66	2.428319	2.260728	11.7
71.26	-26.44	20.7	2.6	2.470177	2.158693	10.5
71.58	-27.92	20.07	2.57	2.460794	2.020007	10.4
71.84	-28.93	20.27	2.55	2.440075	2.504402	8.4
57.33	-32.05	19.07	2.51	2.487163	3.06524	6.255
57.61	-32.95	19.42	2.52	2.469526	4.151719	3.5
75.19	-34.9	23.38	2.68	2.410102	2.143675	12.5
70.64	-33.3	22.45	2.66	2.386625	2.243989	13.6
68.78	-34.4	21.87	2.61	2.425976	1.969532	13
65.41	-36.99	21.56	2.53	2.372395	1.857519	13.6
59.49	-41.01	20.44	2.48	2.401943	1.866745	12.8
50.4	-43.95	19.19	2.45	2.375275	1.947224	13.018
45.36	-44.53	18.64	2.45	2.467737	2.228873	10.3
43.39	-50.54	18.17	2.46	2.418452	1.890676	13.1
43.29	-58.39	18.33	2.47	2.443691	1.976738	11.6
44.74	-51.29	18.75	2.47	2.43842	1.863092	12.2
46.93	-38.35	18.86	2.46	2.419282	1.834948	13
46.94	-43.61	18.34	2.46	2.401586	1.791395	13.8
47.88	-48.52	17.76	2.47	2.379459	1.746445	14.596
49.6	-48.1	17.46	2.48	2.416626	1.805627	14.3
43.13	-49.56	17.34	2.47	2.250982	4.656832	14
42.73	-48.82	17.6	2.46	2.299354	2.101296	16.7
43.87	-46.9	17.6	2.44	2.372139	2.400559	14.1
38.41	-44.44	19.9	2.41	2.413886	2.054896	13.778
40.17	-44.07	20.37	2.39	2.32877	1.791585	17.9
36.93	-47.04	19.55	2.39	2.366479	1.72126	12.404

36.23	-47.36	19.42	2.39	2.362119	1.786575	16.4
37.6	-41.49	21.02	2.41	2.341878	5.08565	1.612
37.49	-41	20.62	2.4	2.580464	8.70189	1.274
51.55	-38.71	18.02	2.45	2.595874	2.005724	3.092
97.23	-14.07	25.14	2.53	2.375129	5.47792	2.849
98.91	-12.76	27.02	2.54	2.505727	3.411305	3.544
98.73	-12.69	27.73	2.53	2.465478	5.209042	2.023
53.41	-20.34	16.16	2.52	2.351805	1.76779	16.228
52.38	-21.52	16.59	2.52	2.335496	1.752244	15.947
38.81	-36.51	16.86	2.42	2.476331	2.372235	11.6
62.77	-30.05	18.95	2.47	2.524347	1.915326	9.1
55.04	-32.01	20.51	2.43	2.538312	2.034396	7.1
42.32	-33.95	17.21	2.38	2.317996	2.135731	18
40.64	-34.63	16.48	2.39	2.297459	1.951233	18.6
40.83	-35.15	16.34	2.4	2.296027	1.759159	18.6
39.28	-36.88	22.94	2.36	2.28009	1.736251	19
40.02	-35.71	22.9	2.36	2.339158	1.851411	17.8
41.91	-44.11	20.6	2.36	2.37026	1.896247	15.6
41.43	-44.03	20.26	2.36	2.403809	2.845942	15.7
39.55	-29.47	21.16	2.33	2.279534	2.17555	17.9
41.88	-27.41	21.02	2.35	2.28479	1.970753	18.6
50.14	-28.89	22.34	2.42	2.328105	2.03753	17.8
54.73	-28.26	24.43	2.48	2.337909	2.134778	16.4
45.41	-22.88	22.36	2.37	2.392682	2.138076	13.6
44.89	-25.78	20.33	2.36	2.295352	1.962395	17.4
46.85	-29.24	19.42	2.38	2.204357	5.482797	15.6
46.47	-29.03	19.39	2.4	2.310828	2.283579	15.9
46.03	-39.64	19.48	2.39	2.347308	2.025642	15.3
48.68	-31.98	19.17	2.38	2.277204	2.003552	17.364
49.7	-26.79	19.21	2.39	2.324019	1.987369	17.2
49.14	-27.23	19.29	2.39	2.277622	2.252975	18.3

49.15	-31.98	19	2.39	2.405283	1.847764	13.2
46.53	-38.78	19.23	2.41	2.309981	1.739363	17.7
47.75	-30.26	19.09	2.41	2.348091	1.663063	18.1
45.85	-26.61	18.92	2.4	2.33103	1.618857	16.2
46.87	-26.62	18.7	2.39	2.344617	1.806221	18.446
46.1	-27.62	18.7	2.39	2.359865	1.867406	15.8
42.57	-26.92	19.1	2.37	2.316804	3.662389	17.354
43.6	-27.46	19.33	2.35	2.314144	1.959344	14.6
48.63	-28.93	19.88	2.38	2.347544	1.816716	15.6
51.78	-29.16	20.28	2.37	2.381771	2.238919	16.5
52.45	-29.85	20.34	2.38	2.321541	3.463827	16
51.42	-34.28	20.42	2.37	2.320438	2.230164	20.692
51.15	-37.34	20.3	2.35	2.336654	1.936716	18.2
51.48	-39.07	20.45	2.35	2.29031	1.876827	19.476
51.7	-42.83	21.07	2.36	2.288529	1.73987	20.368
50.02	-45.44	22.31	2.39	2.272866	1.904131	21.3
51.3	-44.54	22.15	2.44	2.32795	2.268028	19.9
51.17	-37.89	22.58	2.4	2.279102	1.997253	20.336
44.56	-26.57	23.08	2.33	2.309495	6.118771	15.8
44.32	-25.06	23.2	2.32	2.326785	2.298423	16.868
45.64	-24.6	22.77	2.33	2.291359	3.701159	15.6
46.07	-24.4	22.55	2.33	2.348845	3.079838	15.7
44.62	-23.47	23.05	2.33	2.447951	1.985869	11.9
45.75	-23.48	23.1	2.32	2.24033	7.325812	7.5
48.6	-23.57	23.04	2.37	2.506746	8.641913	4.7
49.8	-25.12	22.34	2.45	2.471613	2.423581	9.6
49.91	-25.3	21.66	2.45	2.412121	3.617163	7.584
73	-34.21	18.73	2.52	2.520318	2.077346	8.552
73.38	-33.82	19.17	2.53	2.539025	2.114232	7.242
71.82	-37.35	19.37	2.58	2.532931	2.305114	7.525
68.43	-38.36	18.96	2.61	2.546561	2.316407	6.7

66.86	-38.23	18.71	2.62	2.562369	2.668596	6.3
64.73	-35.63	18.02	2.56	2.49165	1.824097	10.4
61.27	-34.79	18.41	2.54	2.516576	2.169537	7.4
57.79	-38.82	18.8	2.54	2.513135	1.961084	9.436
59.86	-41.69	17.03	2.51	2.476877	1.913622	10.209
61.16	-37.59	17.12	2.49	2.502889	1.880243	10.4
60.68	-37.26	17.24	2.49	2.46086	1.752842	14.6
60.66	-36.97	17.13	2.49	2.413107	2.090752	14.8
60.25	-36.56	17.31	2.49	2.42873	1.811412	14.3
58.82	-35.57	17.95	2.49	2.384463	1.841138	16.4
44.52	-37.43	19.37	2.4	2.394697	1.971778	13.8
42.98	-34.16	19.13	2.39	2.43844	1.962318	12.4
113.85	-24.17	36.36	2.63	2.527222	3.072164	2.782
116.64	-22.24	36.48	2.6	2.530201	3.555316	3.234
114.18	-17.66	34.79	2.54	2.570925	2.322928	1.335
105.97	-16.91	34.53	2.54	2.610431	2.666835	1.821
103.57	-15.99	32.63	2.57	2.603923	2.369093	2.128
91.5	-18.24	30.78	2.6	2.519742	2.540145	2.828
93.34	-20.55	28.03	2.55	2.335279	4.087277	2.659

Apéndice C. Dataset Pozo-3 para el entrenamiento del modelo de predicción de permeabilidad a partir de registros

Input dataset				Target output dataset
GR	SP	LLD	PHI RCAL	k
API	mV	ohm.m	%	mD
87.44	-27.36	3.94	1.9	0.0005
72.42	-26.68	5.37	3.642	0.0028
109.51	-18.19	2.24	2.1	0.0094
106.42	-18.25	2.78	2.2	0.0009

100.08	-18.56	2.86	2.893	6.3247
90.77	-18.95	2.89	3.4	0.2047
79.67	-16.18	12.11	2.999	0.0692
100.43	-22.46	2.68	5.3	0.0164
93.22	-22.72	6.61	4.2	0.0041
86.07	-24.5	12.6	2.305	0.0008
96.48	-27.9	6.25	1.876	0.0004
95.76	-27.73	9.72	3	0.4318
100.73	-17.42	2.78	1.671	0.0019
96.84	-23.35	4.65	2.1	0.0005
95.26	-19.19	7.9	3.357	0.0263
90.03	-20.26	26.39	4.6	0.0499
86.01	-23.93	32.8	5.8	0.0142
72.38	-27.09	59.65	9.5	0.1199
70.4	-24.35	37.99	11.7	0.959
71.26	-26.44	34.23	10.5	0.2995
71.58	-27.92	37.69	10.4	0.2978
71.84	-28.93	31.96	8.4	0.0613
57.33	-32.05	28.62	6.255	0.0364
57.61	-32.95	37.59	3.5	0.0023
75.19	-34.9	21.23	12.5	3.2049
70.64	-33.3	34.74	13.6	4.5248
68.78	-34.4	28.5	13	4.6368
65.41	-36.99	37.8	13.6	7.8311
59.49	-41.01	40.63	12.8	4.1544
50.4	-43.95	37.9	13.018	5.4975
45.36	-44.53	37.34	10.3	0.9292
43.39	-50.54	36.97	13.1	4.3795
43.29	-58.39	30.59	11.6	1.2888
44.74	-51.29	32.19	12.2	2.9362
46.93	-38.35	35.04	13	4.0047

46.94	-43.61	33.75	13.8	8.3939
47.88	-48.52	34.5	14.596	13.6648
49.6	-48.1	35.35	14.3	12.8816
43.13	-49.56	37.22	14	6.4661
42.73	-48.82	36.86	16.7	30.7648
43.87	-46.9	39.68	14.1	5.3828
38.41	-44.44	42.55	13.778	4.8353
40.17	-44.07	46.69	17.9	42.2684
36.93	-47.04	42.74	12.404	20.4464
36.23	-47.36	42.49	16.4	33.6961
37.6	-41.49	56.04	3.092	0.051
37.49	-41	56.03	1.612	0.7693
51.55	-38.71	55.03	1.274	0.0599
97.23	-14.07	3.44	2.849	0.0553
98.91	-12.76	3.67	3.544	0.2079
98.73	-12.69	3.42	2.023	0.0013
53.41	-20.34	11.28	16.228	100.1064
52.38	-21.52	10.38	15.947	131.75
38.81	-36.51	11.7	11.6	10.4104
62.77	-30.05	16.3	9.1	0.25
55.04	-32.01	13.4	7.1	0.0281
42.32	-33.95	5.43	18	111.1008
40.64	-34.63	5.26	18.6	155.1911
40.83	-35.15	5.2	18.6	171.4057
39.28	-36.88	4.83	19	165.5849
40.02	-35.71	4.8	17.8	69.8981
41.91	-44.11	4.94	15.6	17.7294
41.43	-44.03	5.01	15.7	19.7659
39.55	-29.47	4.39	17.9	120.0362
41.88	-27.41	4.43	18.6	216.5897
50.14	-28.89	2.01	17.8	130.0109

54.73	-28.26	1.89	16.4	21.3763
45.41	-22.88	1.7	13.6	7.9476
44.89	-25.78	1.55	17.4	124.5958
46.85	-29.24	1.65	15.6	24.7664
46.47	-29.03	2.38	15.9	42.0407
46.03	-39.64	2.48	15.3	34.8213
48.68	-31.98	1.98	17.364	138.4175
49.7	-26.79	2.3	17.2	95.6915
49.14	-27.23	2.17	18.3	205.6779
49.15	-31.98	2.02	13.2	11.3468
46.53	-38.78	3.38	17.7	139.2371
47.75	-30.26	2.98	18.1	236.1752
45.85	-26.61	2.08	16.2	37.6818
46.87	-26.62	2.07	18.446	181.0474
46.1	-27.62	2.58	15.8	39.4533
42.57	-26.92	2.35	17.354	124.2768
43.6	-27.46	2.04	14.6	7.2746
48.63	-28.93	1.97	15.6	42.349
51.78	-29.16	1.66	16.5	35.7611
52.45	-29.85	1.57	16	39.8628
51.42	-34.28	1.66	20.692	580.4459
51.15	-37.34	1.95	18.2	84.8659
51.48	-39.07	1.97	19.476	374.8666
51.7	-42.83	1.73	20.368	484.157
50.02	-45.44	1.52	21.3	661.7301
51.3	-44.54	1.4	19.9	351.0583
51.17	-37.89	1.39	20.336	466.1708
44.56	-26.57	1.47	15.8	20.508
44.32	-25.06	1.39	16.868	110.8513
45.64	-24.6	1.55	15.6	27.9071
46.07	-24.4	1.56	15.7	79.4928

44.62	-23.47	1.35	11.9	9.6878
45.75	-23.48	1.38	7.5	0.0788
48.6	-23.57	1.38	4.7	0.0003
49.8	-25.12	2.52	9.6	1.0858
49.91	-25.3	3.44	7.584	0.0573
73	-34.21	7.78	8.552	0.1029
73.38	-33.82	3.78	7.242	0.0344
71.82	-37.35	2.28	7.525	0.0426
68.43	-38.36	2.39	6.7	0.0292
66.86	-38.23	2.5	6.3	0.0192
64.73	-35.63	2.75	10.4	0.7499
61.27	-34.79	2.62	7.4	0.0805
57.79	-38.82	2.31	9.436	0.3069
59.86	-41.69	2.32	10.209	0.7476
61.16	-37.59	3.82	10.4	0.6296
60.68	-37.26	4.3	14.6	17.8638
60.66	-36.97	4.55	14.8	26.6023
60.25	-36.56	4.96	14.3	13.2874
58.82	-35.57	6.15	16.4	48.7474
44.52	-37.43	6.12	13.8	60.2317
42.98	-34.16	5.82	12.4	27.5762
113.85	-24.17	6.59	2.782	0.6422
116.64	-22.24	6.6	3.234	0.206
114.18	-17.66	4.27	1.335	0.0002
105.97	-16.91	3.02	1.821	0.0643
103.57	-15.99	4.29	2.128	0.2324
91.5	-18.24	2.99	2.828	0.1473
93.34	-20.55	10.21	2.659	0.164062

Apéndice D. Dataset Pozo-3 para el entrenamiento del modelo de predicción de permeabilidad a partir de registros integrado con tomografía

Input dataset						Target output dataset
GR	SP	LLD	RHOB-CT	PEF-CT	PHI RCAL	<i>k</i>
API	mV	ohm.m	g/cm3	b/e	%	mD
87.44	-27.36	3.94	2.541649	2.681743	1.9	0.0005
72.42	-26.68	5.37	2.571389	2.458046	3.642	0.0028
109.51	-18.19	2.24	2.306487	6.472374	2.1	0.0094
106.42	-18.25	2.78	2.330768	5.792621	2.2	0.0009
100.08	-18.56	2.86	2.551033	2.722564	2.893	6.3247
90.77	-18.95	2.89	2.321836	4.164345	3.4	0.2047
79.67	-16.18	12.11	2.172759	5.929769	2.999	0.0692
100.43	-22.46	2.68	2.5393	2.670922	5.3	0.0164
93.22	-22.72	6.61	2.385941	4.335287	4.2	0.0041
86.07	-24.5	12.6	2.368941	3.95905	2.305	0.0008
96.48	-27.9	6.25	2.531987	2.569074	1.876	0.0004
95.76	-27.73	9.72	2.515693	2.500312	3	0.4318
100.73	-17.42	2.78	2.58102	2.39188	1.671	0.0019
96.84	-23.35	4.65	2.243722	4.988967	2.1	0.0005
95.26	-19.19	7.9	2.286384	5.355557	3.357	0.0263
90.03	-20.26	26.39	2.394074	4.149707	4.6	0.0499
86.01	-23.93	32.8	2.524912	2.37514	5.8	0.0142
72.38	-27.09	59.65	2.473613	2.172127	9.5	0.1199
70.4	-24.35	37.99	2.428319	2.260728	11.7	0.959
71.26	-26.44	34.23	2.470177	2.158693	10.5	0.2995
71.58	-27.92	37.69	2.460794	2.020007	10.4	0.2978
71.84	-28.93	31.96	2.440075	2.504402	8.4	0.0613
57.33	-32.05	28.62	2.487163	3.06524	6.255	0.0364
57.61	-32.95	37.59	2.469526	4.151719	3.5	0.0023

75.19	-34.9	21.23	2.410102	2.143675	12.5	3.2049
70.64	-33.3	34.74	2.386625	2.243989	13.6	4.5248
68.78	-34.4	28.5	2.425976	1.969532	13	4.6368
65.41	-36.99	37.8	2.372395	1.857519	13.6	7.8311
59.49	-41.01	40.63	2.401943	1.866745	12.8	4.1544
50.4	-43.95	37.9	2.375275	1.947224	13.018	5.4975
45.36	-44.53	37.34	2.467737	2.228873	10.3	0.9292
43.39	-50.54	36.97	2.418452	1.890676	13.1	4.3795
43.29	-58.39	30.59	2.443691	1.976738	11.6	1.2888
44.74	-51.29	32.19	2.43842	1.863092	12.2	2.9362
46.93	-38.35	35.04	2.419282	1.834948	13	4.0047
46.94	-43.61	33.75	2.401586	1.791395	13.8	8.3939
47.88	-48.52	34.5	2.379459	1.746445	14.596	13.6648
49.6	-48.1	35.35	2.416626	1.805627	14.3	12.8816
43.13	-49.56	37.22	2.250982	4.656832	14	6.4661
42.73	-48.82	36.86	2.299354	2.101296	16.7	30.7648
43.87	-46.9	39.68	2.372139	2.400559	14.1	5.3828
38.41	-44.44	42.55	2.413886	2.054896	13.778	4.8353
40.17	-44.07	46.69	2.32877	1.791585	17.9	42.2684
36.93	-47.04	42.74	2.366479	1.72126	12.404	20.4464
36.23	-47.36	42.49	2.362119	1.786575	16.4	33.6961
37.6	-41.49	56.04	2.341878	5.08565	3.092	0.051
37.49	-41	56.03	2.580464	8.70189	1.612	0.7693
51.55	-38.71	55.03	2.595874	2.005724	1.274	0.0599
97.23	-14.07	3.44	2.375129	5.47792	2.849	0.0553
98.91	-12.76	3.67	2.505727	3.411305	3.544	0.2079
98.73	-12.69	3.42	2.465478	5.209042	2.023	0.0013
53.41	-20.34	11.28	2.351805	1.76779	16.228	100.1064
52.38	-21.52	10.38	2.335496	1.752244	15.947	131.75
38.81	-36.51	11.7	2.476331	2.372235	11.6	10.4104
62.77	-30.05	16.3	2.524347	1.915326	9.1	0.25

55.04	-32.01	13.4	2.538312	2.034396	7.1	0.0281
42.32	-33.95	5.43	2.317996	2.135731	18	111.1008
40.64	-34.63	5.26	2.297459	1.951233	18.6	155.1911
40.83	-35.15	5.2	2.296027	1.759159	18.6	171.4057
39.28	-36.88	4.83	2.28009	1.736251	19	165.5849
40.02	-35.71	4.8	2.339158	1.851411	17.8	69.8981
41.91	-44.11	4.94	2.37026	1.896247	15.6	17.7294
41.43	-44.03	5.01	2.403809	2.845942	15.7	19.7659
39.55	-29.47	4.39	2.279534	2.17555	17.9	120.0362
41.88	-27.41	4.43	2.28479	1.970753	18.6	216.5897
50.14	-28.89	2.01	2.328105	2.03753	17.8	130.0109
54.73	-28.26	1.89	2.337909	2.134778	16.4	21.3763
45.41	-22.88	1.7	2.392682	2.138076	13.6	7.9476
44.89	-25.78	1.55	2.295352	1.962395	17.4	124.5958
46.85	-29.24	1.65	2.204357	5.482797	15.6	24.7664
46.47	-29.03	2.38	2.310828	2.283579	15.9	42.0407
46.03	-39.64	2.48	2.347308	2.025642	15.3	34.8213
48.68	-31.98	1.98	2.277204	2.003552	17.364	138.4175
49.7	-26.79	2.3	2.324019	1.987369	17.2	95.6915
49.14	-27.23	2.17	2.277622	2.252975	18.3	205.6779
49.15	-31.98	2.02	2.405283	1.847764	13.2	11.3468
46.53	-38.78	3.38	2.309981	1.739363	17.7	139.2371
47.75	-30.26	2.98	2.348091	1.663063	18.1	236.1752
45.85	-26.61	2.08	2.33103	1.618857	16.2	37.6818
46.87	-26.62	2.07	2.344617	1.806221	18.446	181.0474
46.1	-27.62	2.58	2.359865	1.867406	15.8	39.4533
42.57	-26.92	2.35	2.316804	3.662389	17.354	124.2768
43.6	-27.46	2.04	2.314144	1.959344	14.6	7.2746
48.63	-28.93	1.97	2.347544	1.816716	15.6	42.349
51.78	-29.16	1.66	2.381771	2.238919	16.5	35.7611
52.45	-29.85	1.57	2.321541	3.463827	16	39.8628

51.42	-34.28	1.66	2.320438	2.230164	20.692	580.4459
51.15	-37.34	1.95	2.336654	1.936716	18.2	84.8659
51.48	-39.07	1.97	2.29031	1.876827	19.476	374.8666
51.7	-42.83	1.73	2.288529	1.73987	20.368	484.157
50.02	-45.44	1.52	2.272866	1.904131	21.3	661.7301
51.3	-44.54	1.4	2.32795	2.268028	19.9	351.0583
51.17	-37.89	1.39	2.279102	1.997253	20.336	466.1708
44.56	-26.57	1.47	2.309495	6.118771	15.8	20.508
44.32	-25.06	1.39	2.326785	2.298423	16.868	110.8513
45.64	-24.6	1.55	2.291359	3.701159	15.6	27.9071
46.07	-24.4	1.56	2.348845	3.079838	15.7	79.4928
44.62	-23.47	1.35	2.447951	1.985869	11.9	9.6878
45.75	-23.48	1.38	2.24033	7.325812	7.5	0.0788
48.6	-23.57	1.38	2.506746	8.641913	4.7	0.0003
49.8	-25.12	2.52	2.471613	2.423581	9.6	1.0858
49.91	-25.3	3.44	2.412121	3.617163	7.584	0.0573
73	-34.21	7.78	2.520318	2.077346	8.552	0.1029
73.38	-33.82	3.78	2.539025	2.114232	7.242	0.0344
71.82	-37.35	2.28	2.532931	2.305114	7.525	0.0426
68.43	-38.36	2.39	2.546561	2.316407	6.7	0.0292
66.86	-38.23	2.5	2.562369	2.668596	6.3	0.0192
64.73	-35.63	2.75	2.49165	1.824097	10.4	0.7499
61.27	-34.79	2.62	2.516576	2.169537	7.4	0.0805
57.79	-38.82	2.31	2.513135	1.961084	9.436	0.3069
59.86	-41.69	2.32	2.476877	1.913622	10.209	0.7476
61.16	-37.59	3.82	2.502889	1.880243	10.4	0.6296
60.68	-37.26	4.3	2.46086	1.752842	14.6	17.8638
60.66	-36.97	4.55	2.413107	2.090752	14.8	26.6023
60.25	-36.56	4.96	2.42873	1.811412	14.3	13.2874
58.82	-35.57	6.15	2.384463	1.841138	16.4	48.7474
44.52	-37.43	6.12	2.394697	1.971778	13.8	60.2317

42.98	-34.16	5.82	2.43844	1.962318	12.4	27.5762
113.85	-24.17	6.59	2.527222	3.072164	2.782	0.6422
116.64	-22.24	6.6	2.530201	3.555316	3.234	0.206
114.18	-17.66	4.27	2.570925	2.322928	1.335	0.0002
105.97	-16.91	3.02	2.610431	2.666835	1.821	0.0643
103.57	-15.99	4.29	2.603923	2.369093	2.128	0.2324
91.5	-18.24	2.99	2.519742	2.540145	2.828	0.1473
93.34	-20.55	10.21	2.335279	4.087277	2.659	0.164062

Apéndice E. Script compilado en Matlab del modelo entrenado para la predicción de porosidad a partir de registros

Enlace: <https://shortest.link/ePDy>

Nota. Los códigos fueron cargados en un repositorio público de GitHub, plataforma diseñada para compartir proyectos relacionados con códigos fuente de diversas aplicaciones. Puede acceder a los enlaces para visualizarlos, o bien acceder directamente a los archivos *.m* desde la base de datos de la biblioteca UIS.

Apéndice F. Script compilado en Matlab del modelo entrenado para la predicción de porosidad a partir de registros con tomografía

Enlace: <https://shortest.link/ePFk>

Apéndice G. Script compilado en Matlab del modelo entrenado para la predicción de permeabilidad a partir de registros

Enlace: <https://shortest.link/ePER>

Apéndice H. Script compilado en Matlab del modelo entrenado para la predicción de permeabilidad a partir de registros con tomografía

Enlace: <https://shortest.link/fy1x>

Apéndice I. Script del modelo de integración de datos de registros con tomografía para la predicción de porosidad

Enlace: <https://shortest.link/fzeg>

Nota. Para usar los modelos de integración de los Apéndices I y J, se presenta el siguiente paso a paso:

1. Descargue los archivos *.m* según corresponda el modelo que necesite aplicar. Para el modelo de integración para la predicción de porosidad, los scripts: *integrationmodel_porosity.m* y su respectivo script del modelo entrenado *neuralnetworkfunction_logsduallctm.m*. Para el modelo de integración para la predicción de permeabilidad, los scripts: *integrationmodel_permeability.m* y su respectivo script del modelo entrenado *neuralnetworkfunction_logsduallctm.m*. Guárdelos en una carpeta asignada para trabajar con Matlab.
2. Cargue los datos de registro y tomografía organizados en un archivo de formato compatible con Matlab, como *.xlsx* o *.txt*. Los datos deben estar distribuidos como lo requiere el modelo y su orden se muestra en el encabezado de cada código.

Para el modelo de porosidad:

```
%INTEGRATIONMODEL_POROSITY integration model function.
%
% [w] = integrationmodel_porosity(x) toma estos argumentos:
%   v1 = Px5 matriz, input #1 (Con vectores columna, en orden: Depth (ft), GR (API), SP (mV), NPFI(%), RHOB(g/cm3))
%   v2 = Qx3 matriz, input #2 (Con vectores columna, en orden: Depth (ft), RHOB-CT (g/cm3), PEF-CT (b/e))
% y genera:
%   w = Qx2 matriz, output #1 (Con vectores columna, en orden: Depth (ft), PHI(%))
% donde P es el número de muestras de registros y Q es el número de muestras de tomografía.
```

Para el modelo de permeabilidad:

```
%INTEGRATIONMODEL_PERMEABILITY integration model function.
%
% [w] = integrationmodel_permeability(x) toma estos argumentos:
% v1 = Px4 matriz, input #1 (Con vectores columna, en orden: Depth (ft), GR (API), SP (mV), LLD(ohm.m))
% v2 = Qx3 matriz, input #2 (Con vectores columna, en orden: Depth (ft), RHOB-CT (g/cm3), PEF-CT (b/e))
% v3 = Qx2 matriz, input #3 (Con vectores columna, en orden: Depth (ft), PHI high resolution(%))
% y genera:
% w = Qx2 matriz, output #1 (Con vectores columna, en orden: Depth (ft), K(mD))
% donde P es el número de muestras de registros y Q es el número de muestras de tomografía y porosidad.
```

3. Las matrices v1, v2 y v3, según el modelo, son variables que pueden ser asignadas en Matlab a partir de los archivos cargados. Puede cargar los datos a partir de los archivos incluidos en la carpeta de trabajo mediante la función *readmatrix*. Por ejemplo:

```
v1 = readmatrix('logsdata.xlsx');
```

Así mismo para cargar los datos de tomografía, y los datos de porosidad en el caso del modelo de permeabilidad.

4. Con los datos cargados y asignados en las variables correspondientes, ejecutar la función del modelo guardando los resultados en una variable nueva como se muestra a continuación:

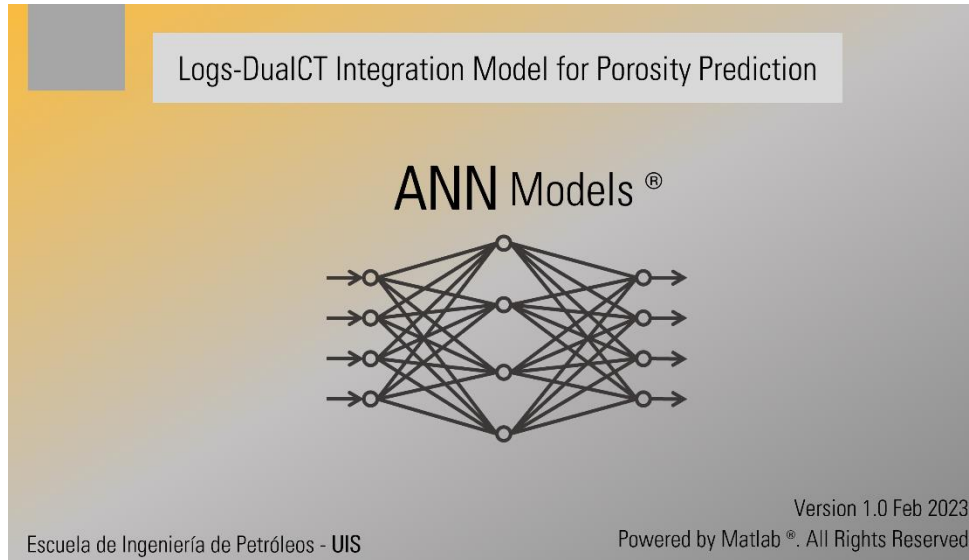
```
permeabilityPred = integrationmodel_permeability(v1,v2,v3);
```

5. El script además de generar los resultados de los valores estimados también genera los gráficos de validación para los registros de pozo, la información de tomografía y la porosidad o permeabilidad estimada.
6. Tener en cuenta los datos nulos estimados a partir de los datos nulos de tomografía.

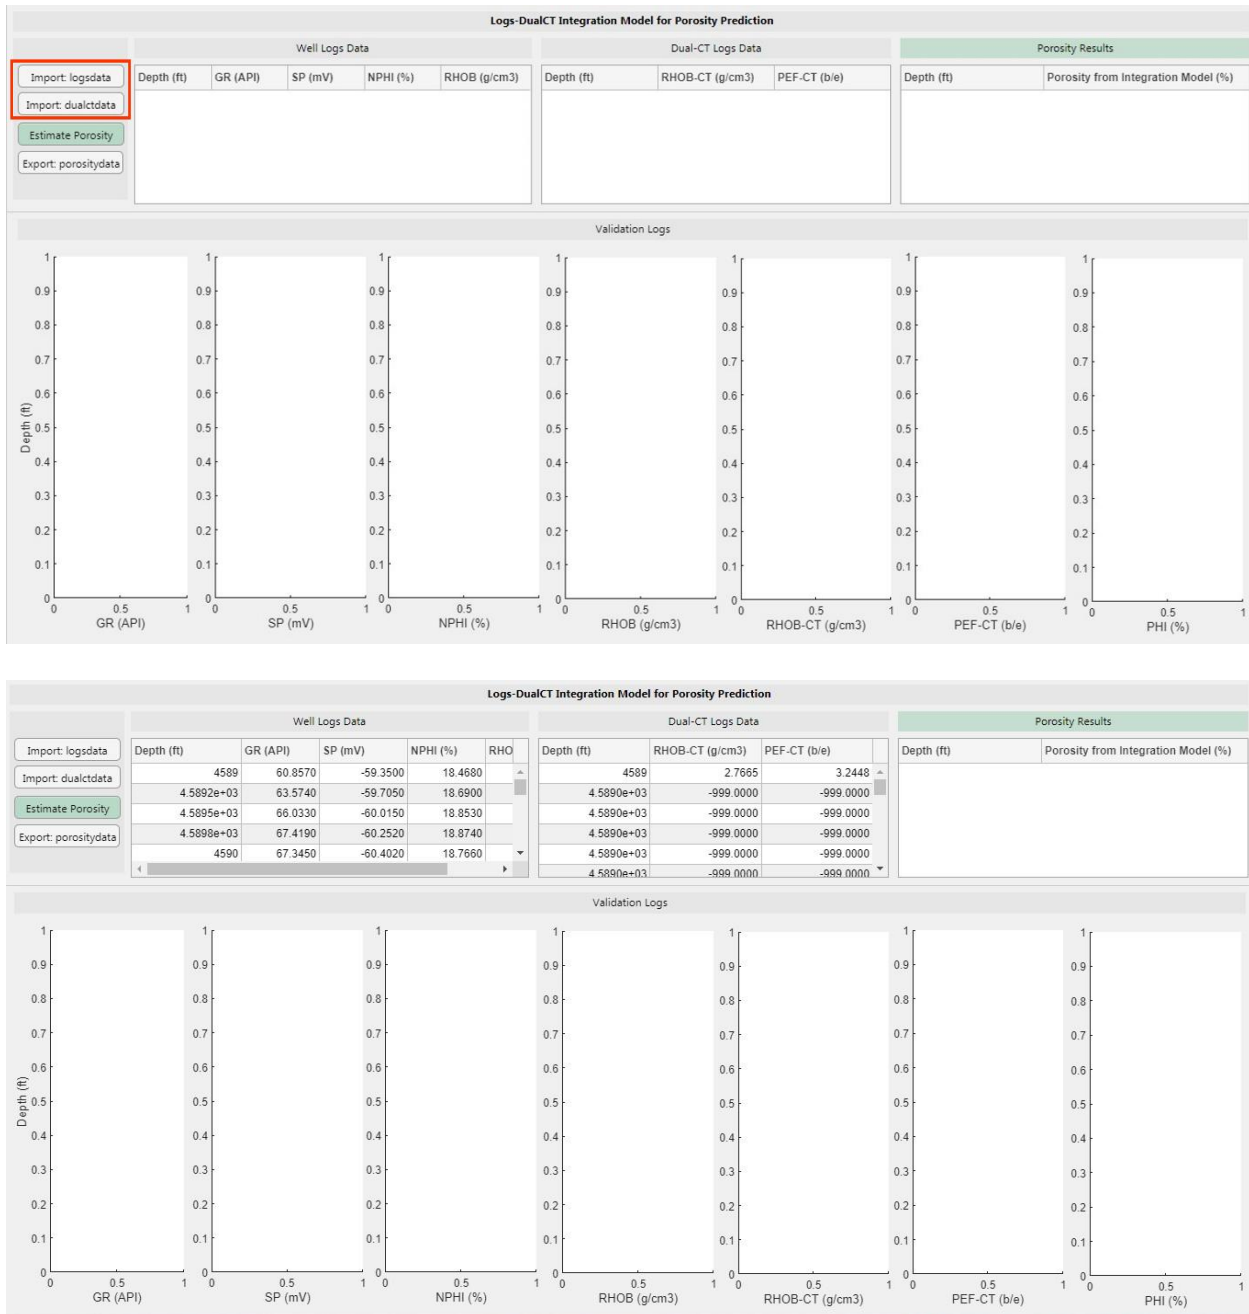
Apéndice J. Script del modelo de integración de datos de registros con tomografía para la predicción de permeabilidad

Enlace: <https://shortest.link/gk6G>

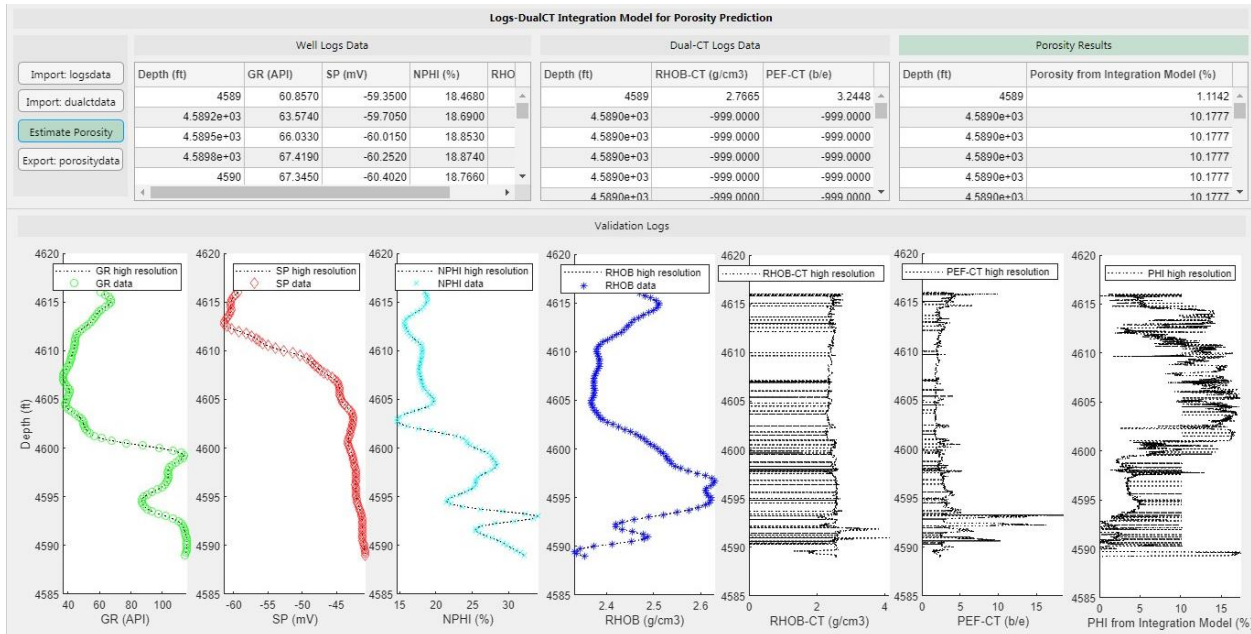
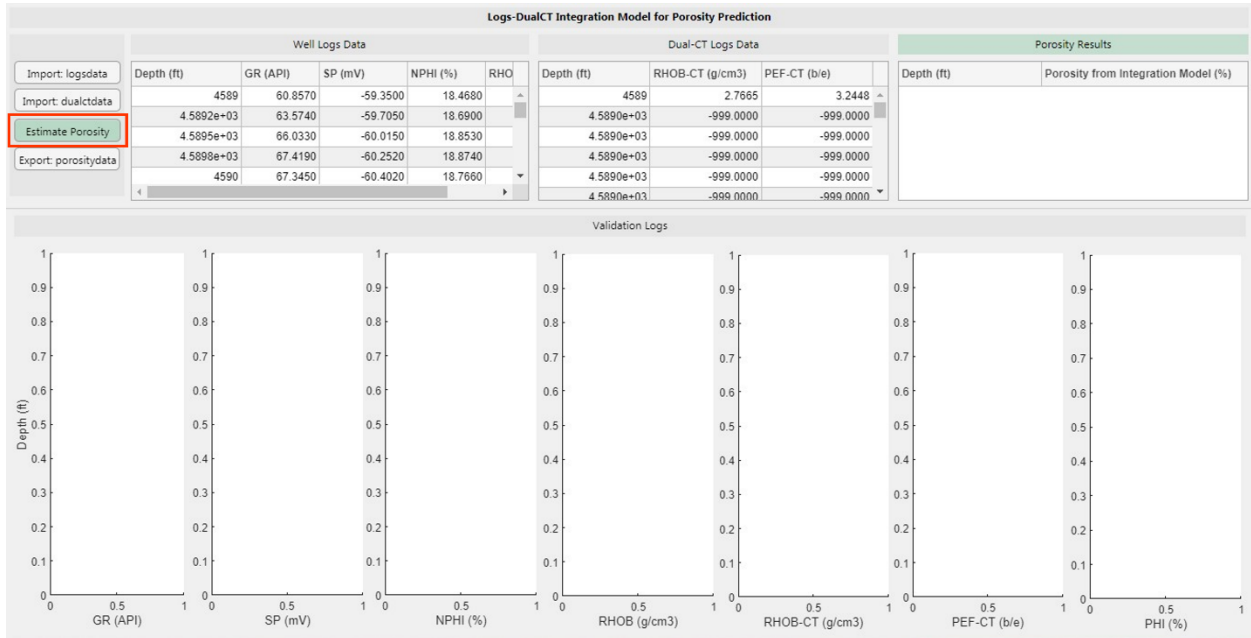
Apéndice K. Modelo interactivo para la predicción de porosidad integrando datos de registros con tomografía



Nota. Los modelos interactivos de los apéndices K y L fueron compilados usando las herramientas *App Designer* y *App Compiler* de Matlab, cada una implementando los modelos de integración que se muestran en los apéndices I y J, respectivamente. Las aplicaciones permiten al usuario cargar los archivos de registros, de tomografía y/o de porosidad, de manera independiente en formato Excel (.xlsx), como se muestra a continuación:



Con los datos de registro y tomografía cargados, se selecciona el botón “Estimate Porosity”/“Estimate Pemeability” y se validan los resultados mediante los gráficos y la tabla de valores estimados:



El modelo interactivo también permite exportar los datos estimados en formato Excel seleccionando el botón “Export: porositydata”/“Export: permeability”.

Apéndice L. Modelo interactivo para la predicción de permeabilidad integrando datos de registros con tomografía

