



LOS LIBERTADORES
FUNDACIÓN UNIVERSITARIA

**CLASIFICACIÓN LITOLÓGICA A PARTIR DE REGISTROS ELÉCTRICOS
UTILIZANDO MACHINE LEARNING: CASO DE ESTUDIO FORMACIÓN
OTARAOA, NUEVA ZELANDA.**

LITHOLOGICAL CLASSIFICATION FROM WELL LOGS USING MACHINE LEARNING:
CASE STUDY OTARAOA FORMATION, NEW ZEALAND.

Margarita María Martínez Bernal, mmmartinezb@libertadores.edu.co

José John Fredy González Veloza, jjgonzalezv02@libertadores.edu.co

RESUMEN

En la industria del petróleo, al perforar un pozo de exploración, la incertidumbre es excesivamente alta ya que se quiere determinar las características del subsuelo y así las posibilidades de que exista petróleo o gas. Los métodos indirectos como la toma de registros eléctricos son los que proporcionan la base para los estudios de investigación geológica (facies sedimentarias, aguas subterráneas) lo cual es una actividad compleja que requiere tiempo pero que permiten al evaluador tomar decisiones. Mediante la aplicación de un modelo de aprendizaje automático se quiere reducir esta incertidumbre y minimizar el tiempo en el análisis de los registros eléctricos. En este estudio, se investiga la predicción de litología utilizando los registros eléctricos (Rayos Gamma, Neutrón, Densidad y Efecto fotoeléctrico (PEF)) tomados en la Fm. Otaraoa en Nueva Zelanda. Se realiza el entrenamiento de un modelo Supervisado en donde se abordan dos problemas: el primero de identificación de dos etiquetas (Arena y Arcilla) y el segundo de cuatro etiquetas (Arcilla arenosa, Arcilla arenosa calcárea, Arena arcillosa y Arena arcillosa calcárea). Se utiliza un pozo para entrenar un algoritmo para cada caso y luego dos pozos complementarios para probar su desempeño. Los resultados del modelo Extra Trees Classifier muestran que para el *Problema 1* se obtuvo un *Accuracy* del



93%, superando las métricas del modelo basado en reglas (*Accuracy* del 87%), mientras que en el *Problema 2* el *Accuracy* fue del 86%. El modelo en el *Problema 1* logró aprender a reconocer la litología preestablecida por el experto humano y para el *Problema 2* es importante seguir alimentando el entrenamiento del modelo con mayor cantidad de datos de otros pozos o con descripciones litológicas de núcleos.

Palabras clave: Registros Eléctricos, litología, Aprendizaje supervisado, Clasificación

ABSTRACT

In the oil industry, when exploration well drilling, the uncertainty is excessively high since it is necessary to determine the characteristics of the subsurface and thus the possibilities that oil or gas exists. Indirect methods such as well logs are what provide the basis for geological investigation studies (sedimentary facies, groundwater) which is a complex activity that requires time but allows the evaluator to make decisions. By applying an automatic learning model, we want to reduce this uncertainty and minimize the time in the analysis of well logs. In this study, lithology prediction is investigated using electrical logs (Gamma Rays, Neutron, Density and Photoelectric Effect (PEF)) taken at the Fm. Otaraoa in New Zealand. The training of a Supervised model is carried out where two problems are addressed: the first of identification of two labels (Sand and Clay) and the second of four labels (Sandy Clay, Calcareous Sandy Clay, Clayey Sand and Calcareous Clayey Sand). One well is used to train an algorithm for each case and then two complementary wells are used to test its performance. The results of the Extra Trees Classifier model show that for *Problem 1* an *Accuracy* of 93% was obtained, exceeding the metrics of the model based on rules (*Accuracy* of 87%), while in *Problem 2* the *Accuracy* was 86%. The model in *Problem 1* will learn to recognize the lithology pre-established by the human expert and for *Problem 2* it is important to continue feeding the model training with more data from other wells or with core descriptions.

Keywords: Well Log data, Lithology, Supervised Learning, Classification



INTRODUCCIÓN

En la industria del petróleo, al perforar un pozo de exploración, la incertidumbre es excesivamente alta ya que se quiere determinar las posibilidades de que exista petróleo o gas a grandes profundidades. Los métodos indirectos como la toma de registros eléctricos son los que proporcionan la base para los estudios de investigación geológica (facies sedimentarias, aguas subterráneas) lo cual es una actividad compleja que requiere tiempo pero que permiten al evaluador tomar decisiones. Tener la capacidad de entender y predecir los cambios en las características que sufren los registros eléctricos, reduce la incertidumbre de las decisiones y pueden ser de gran impacto en la reducción de la inversión para las compañías petroleras.

Los registros eléctricos son una fuente de datos complementaria y la reciente explosión de algoritmos de aprendizaje automático ha brindado a los investigadores la oportunidad de desarrollar herramientas estadísticas para clasificar automáticamente la litología en estos registros eléctricos (Horrocks et al., 2015), lo que permite a los geólogos producir rápidamente interpretaciones de primer paso y validar otras, incluso cuando las muestras de núcleo faltan por partes, se encuentran astillados o faltan en su totalidad (Pillado, 2016).

En los últimos años la clasificación litológica, a través del aprendizaje automático, se ha realizado con varios métodos importantes, Naive Bayes (Horrocks et al., 2015, Xie et al., 2018), Convolutional neural network (Tsanda et al., 2018; Kanfar et al., 2020), Artificial neural network (Horrocks et al., 2015; Xie et al., 2018), Logistic regression (Singh & Myshakin, 2020), métodos para datos no supervisados, como k-means clustering (McCreery & Al-Mudhafar, 2017; Singh & Myshakin, 2020), k-medians clustering, Gaussian and Bayesian Mixture Model, Decision tree (Singh & Myshakin, 2020), SVM (Horrocks et al., 2015; Xie et al., 2018; Bressan et al., 2020; Singh & Myshakin, 2020), Random Forest (Xie et al., 2018), Gradient Tree Boosting (Xie et al., 2018) y Partitioning Around Medoids (McCreery & Al-Mudhafar, 2017).

La información adicional que es proporcionada por los registros eléctricos, que pueden ser muy numerosos, supone una carga para los geólogos, quienes deben



integrarla con su flujo de trabajo e interpretar la litología con limitaciones de tiempo (Horrocks et al., 2015). La clasificación de litología basada en datos de registros de pozos es la base de los cálculos de parámetros de yacimientos, y proporciona la base para los estudios de investigación geológica en campo, como lo son las facies sedimentarias y el ambiente de formación (Xie et al., 2018), si la identificación se hace de modo tradicional (inspección visual) resulta ser una actividad compleja (Álzate et al., 2006), y no siempre es confiable porque diferentes geólogos pueden brindar diferentes interpretaciones (Akinyokun, 2009). Además, un geólogo inexperto, sin conocimiento de la geología de campo, puede no determinar con precisión litologías similares; por lo tanto, el uso de modelos entrenados podría resolver el problema de la falta de conocimiento de campo entre los geólogos y geofísicos (McCreery et al., 2017). En los últimos años, el uso de software como por ejemplo Techlog de Schlumberger (<https://www.software.slb.com/products/techlog>) o DecisionSpace de Halliburton (<https://www.halliburton.com/en/software>), que se utilizan para predecir automáticamente la litología, se ha convertido en un aspecto importante en perforación y registro de pozos. Estas tecnologías informáticas ayudan a los geólogos a evitar el trabajo innecesario de análisis de datos y mejoran la precisión de la identificación de la litología (Xie et al., 2018), sin embargo, son solo utilizados por grandes compañías que pueden tener acceso a estos softwares. Por lo anterior, el objetivo de este trabajo es poder identificar, por medio de la relación de diferentes registros eléctricos, la litología presente en un segmento de un pozo petrolero, para así poder disminuir el tiempo de identificación. La eficiencia de la clasificación litológica se puede mejorar utilizando aplicaciones capaces de producir decisiones más objetivas en lugar de métodos de interpretación más convencionales (Jahdhami & Anboori, 2017).

Mediante la aplicación de un modelo de aprendizaje automático lo que se quiere es tratar de reducir la incertidumbre en la toma de decisiones para las pruebas de pozo, especialmente en los intervalos que no han sido extraídos. Esto resultaría en una reducción de los costos generales de la adquisición de datos, de los costos del proyecto, de los tiempos del ciclo del proyecto y de los costos de exploración (McCreery & Al-Mudhafar, 2017) dado que estas mediciones petrofísicas se



implementan de forma selectiva ya que son costosas de adquirir. Sin embargo, los algoritmos de aprendizaje automático deben evaluarse en el caso de que los pozos contengan una gran cantidad de registros tomados (Horrocks et al., 2015).

El método de aprendizaje supervisado procesa la entrada de datos de referencia para crear un modelo para la predicción de nuevos datos. Para este entrenamiento, el algoritmo requiere datos en un formato y tipo estándar, así como datos con valores confiables y precisos, extraídos de fuentes relevantes con la capacidad de mejorar la retroalimentación (Bressan et al., 2020). En este trabajo, se investiga la predicción de litología utilizando algoritmos de aprendizaje automático para los datos geológicos de Nueva Zelanda y se realiza el entrenamiento de un modelo Supervisado en donde se abordan dos problemas, uno de identificación de dos etiquetas (Arena y Arcilla) y el otro de cuatro etiquetas (Arcilla arenosa, Arcilla arenosa calcárea, Arena arcillosa y Arena arcillosa calcárea). Se utiliza un pozo para entrenar un algoritmo para cada caso y luego, en dos pozos complementarios para prueba, se realiza la evaluación del rendimiento del algoritmo entrenado para la predicción de la litología. Los registros que se utilizan son los de Rayos Gamma, Neutrón, Densidad y Efecto fotoeléctrico (PEF), los cuales son considerados en la industria de suma importancia para la estimación y explotación de los recursos del subsuelo.

METODOLOGÍA

Datos

Para este trabajo se procesa un conjunto de datos abiertos de registros de pozos de la cuenca de Taranaki alojados en IBM Developer Data Asset eXchange disponibles en la siguiente dirección:

https://developer.ibm.com/exchanges/data/all/taranaki-basin-curated-well-logs/?mhsrc=ibmsearch_a&mhq=taranaki.

Este conjunto de datos contiene detalles sobre 407 pozos de petróleo ubicados dentro de la cuenca, la cual comprende un área de aproximadamente 330.000 km², ubicada en Nueva Zelanda. La cuenca está formada por rocas sedimentarias que



datan del Cretácico Superior al presente, cubriendo las rocas del basamento Paleozoico y Mesozoico.

Los datos se seleccionaron de dos fuentes, la primera, la base de datos de exploración en línea de petróleo y minerales de Nueva Zelanda (data.nzpam.govt.nz) y la segunda, Petlab (pet.gns.cri.nz), luego se reunió todo en archivo CSV que contiene los 11 registros (Tabla 1) y coordenadas de los pozos, y las etiquetas correspondientes, como nombre del pozo, formación geológica y otros.

Tabla 1. Registros contenidos en el conjunto de datos de los pozos de Nueva Zelanda.

	Nombre	Unidades	Usos
GR	Rayos Gamma	API	Refleja el contenido arcilloso de las formaciones, debido a que en las formaciones arcillosas se concentran elementos radioactivos tales como el Torio y Potasio.
NEUT	Neutrón	p.u.	Usado principalmente para interpretar la porosidad de la formación y responden a la cantidad de hidrogeno. Así, en arenas limpias, llenas con agua o aceite, el registro Neutrón refleja la cantidad de porosidad llena de líquido. También permite identificar zonas de gas al compararse con el registro Densidad.
DENS	Densidad	g/cc	Usado como registro de porosidad. Otros usos incluyen identificación de minerales y de gas, determinación de la densidad de hidrocarburos y evaluación de arenas arcillosas y litologías complejas.
SP	Potencial espontáneo	mV	Diferencia rocas porosas y permeables de aquellas que no lo son, define límites entre las capas y permite la determinación de la resistividad del agua de formación.
PEF	Efecto fotoeléctrico	Barns/electron	Identificación y discretización de la mineralogía.
DTC	Lentitud de compresión	us/ft	Determinación de porosidad, fracturas, capas, principalmente
DRHO	Densidad-porosidad	g/cc	Corrección del registro Densidad, su rango indica si la herramienta Densidad estaba haciendo un buen contacto con la formación y si las lecturas son confiables
RESD	Resistividad profunda	ohm.m	Se emplea en la determinación de la saturación de agua en las formaciones y geometría de la estructura poral. Esta es la lectura más profunda de la formación
RESS	Resistividad somera	ohm.m	Se emplea en la identificación del perfil de invasión, lee la zona de transición de la formación en la cual hay afectación parcial por los fluidos de perforación
RESM	Resistividad media	ohm.m	Se emplea en la identificación del perfil de invasión, lee la zona de invasión de la formación en la cual hay afectación total por los fluidos de perforación
CALI	Caliper	in	El caliper permite identificar el estado del hoyo. Se puede realizar una interpretación de derrumbe o de colapso de acuerdo a los brazos de la herramienta disponibles en la medición.



Preparación inicial de los datos y las variables

El primer paso fue la selección de las variables de entrada, para este trabajo se utilizaron los registros de GR, NEUT, DENS y PEF dado que en conjunto proporcionan una respuesta efectiva para la identificación de la litología. Por ejemplo, el registro de Densidad se utiliza principalmente para la determinación de la porosidad, por ejemplo, baja densidad indica alta porosidad (Akinyokun, 2009). Las curvas Densidad y Neutrón responden a la litología, y son indicadores de fluido y gas, pero sobre todo de la densidad de la matriz de la roca, esta densidad da un indicador, junto con el PEF, de los minerales que contiene la roca y que corresponden a cada litología (Tabla 1). Acorde a esto, el registro Rayos Gamma refleja el contenido arcilloso de las rocas y mide la radiactividad natural en la roca. Las areniscas dan lecturas bajas de rayos gamma y a medida que aumenta el contenido de arcilla, aumenta el valor de la lectura del registro.

Para este trabajo se tomaron los datos pertenecientes a la Formación Otaraoa en el Pozo Ahuroa-1A, esto debido a que esta formación cuenta con los cuatro registros completos. Esta formación se encuentra dentro del intervalo de profundidad de 2864.51 – 3152.85 pies. Teniendo los datos de los valores de los registros, mediante el software Interactive Petrophysics (<http://www.geoenergy-eg.com/ip-interactive-petrophysics/>), se calculó el porcentaje de volumen de las tres litologías principales y así se logró hacer una etiqueta (manual) de la litología principal contenida en cada punto de profundidad, en este caso, para el *Problema 1* las etiquetas corresponden a Arena, Arcilla y Calcáreo, y para el *Problema 2* corresponden a Arcilla arenosa, Arcilla arenosa calcárea, Arena arcillosa y Arena arcillosa calcárea.

Preprocesamiento y modelación

Para el análisis de los datos y el entrenamiento de los modelos se utiliza el lenguaje de programación Python (versión 3.7.13). Se observa que existen algunos datos faltantes lo cual puede deberse a problemas con los instrumentos de medición durante la adquisición de datos, optimización de costos durante el registro geofísico o factores humanos. La base de datos se depura eliminando los datos nulos del



registro de densidad y de la etiqueta litología, al igual que los datos de litología calcárea por no ser representativos. Para los 167 datos nulos pertenecientes al registro de Rayos Gamma se realiza la técnica de imputación *iterativa*, en este tipo de imputación se utilizan estimadores de regresión y clasificación para modelar cada característica como una función de otras características. Cada característica se imputa de forma rotatoria, y las predicciones anteriores se utilizan en las nuevas (Baum, 2020). Luego de realizar estas depuraciones se cuenta con 1812 datos de profundidad.

Para crear el modelo supervisado, teniendo en cuenta que la variable a predecir es la de litología, se utiliza la librería Pycaret (<https://pycaret.org>) que realiza un análisis global de posibles modelos de clasificación para la predicción de la litología, esta librería arroja las métricas de evaluación de los 10 mejores algoritmos posibles y de ahí se escoge el modelo que se debe utilizar para superar las métricas del modelo basado en reglas creado en primera instancia. El modelo basado en reglas o modelo base, es un modelo básico que se realiza a partir de la relación entre los registros, apoyándose en el diagrama de pares que permite comprender la relación entre los diferentes registros del conjunto de datos. El modelo basado en reglas explica mejor en la sección de resultados.

El modelo supervisado se escoge de acuerdo al *Accuracy* o exactitud (*i. e.*, proporción de ejemplos que se encuentran bien clasificados) y a las métricas de su desempeño, tales como *Precision* o especificidad (*i. e.*, proporción de identificados como positivos que fue correcta de todos los casos identificados como positivos), *Recall* o sensibilidad (*i. e.*, proporción de todos los positivos que se identificaron correctamente), y el puntaje *F1* (*i. e.*, combina las medidas de *Precision* y *Recall* en un sólo valor), y también se analiza la matriz de confusión para ambos problemas. Por último, se evalúa el modelo supervisado en los dos pozos de prueba.

En este trabajo el modelo con las mejores métricas fue el Extra Trees Classifier que es un método de aprendizaje por conjuntos basado fundamentalmente en árboles de decisión. Crea varios árboles y divide nodos utilizando subconjuntos aleatorios de características, no utiliza Bootstrap lo que significa que muestrea sin reemplazar.



También aleatoriza ciertas decisiones y subconjuntos de datos para minimizar el sobreaprendizaje de los datos y el sobreajuste (Bhandari, 2018).

RESULTADOS

En el Análisis Descriptivo se observa que respecto a registro de Densidad se aprecian dos grupos concentrados hacia los valores de 2.35 g/cc y 2.55 g/cc, respectivamente, lo que evidencia los dos grupos de litología para el *Problema 1*, para el *Problema 2* existen los mismos dos grupos solo que a cada grupo le pertenecen dos etiquetas diferentes dependiendo si es calcáreo o no. Respecto a registro de Rayos Gamma, existen dos grupos, uno concentrado hacia valores de 50 API y el otro hacia valores de 70 API, lo que hace referencia a un grupo de arena y otro de arcilla. Para el registro `PEF` se observa que los valores están presentando la mayor concentración de los datos hacia los valores menores de 2.5 Barns/electron equivalentes a valores que representan la litología de arena, la cual es la litología predominante en el *Problema 1*.

Posterior al análisis descriptivo se creó un Modelo basado en reglas teniendo como referente el diagrama de pares (Figura 1), en el que se observa un grupo de Arcilla definido hacia la parte superior derecha y en contraste, uno de Arena hacia la parte inferior izquierda, el cual se ve más definido en la relación de los Registros Neutrón y Rayos Gamma. Es por esto que el modelo base se crea bajo la hipótesis de: “es Arcilla si el registro de Rayos Gamma es mayor a 60 API y el Neutrón mayor a 0.15 pu.”. Lo anterior se debe a que los valores altos de Rayos Gamma son un indicativo de la presencia de elementos radioactivos como Torio, Potasio y Uranio presentes en las arcillas. Por otra parte, el registro Neutrón con valores altos indica que también se está en presencia de Arcilla, ya que estas, al absorber agua están asociadas a cantidades de hidrogeno que reaccionan con los neutrones y marcan un valor alto en el registro.

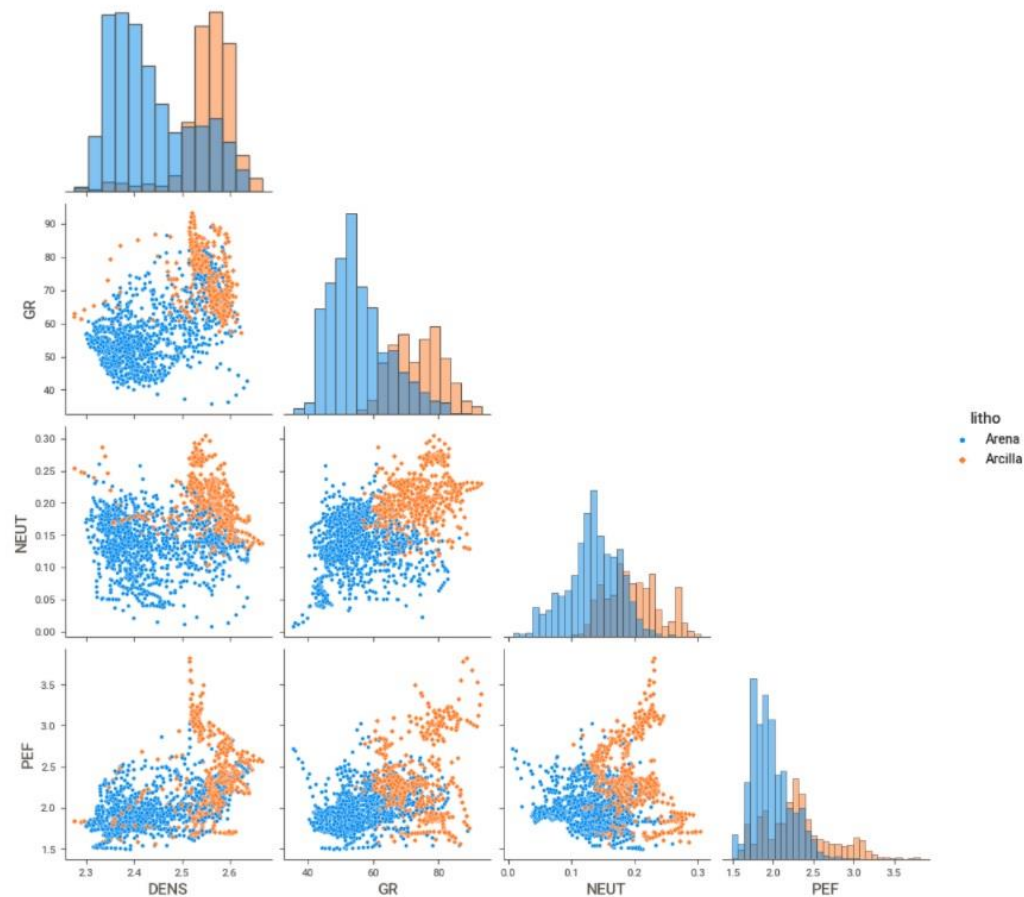


Figura 1. Diagrama de pares *Problema 1*. Comparación de los registros eléctricos donde se observan las diferencias entre los dos grupos de litología, estas son más claras en la comparación de los registros de NEUT y GR.

El modelo base, trabajado con las variables NEUT y GR muestra un 87% de *Accuracy* y las métricas de su desempeño, tales como *Precision*, *Recall* y el puntaje *F1* se muestran en la Tabla 2. Estos valores se utilizaron para comparar el desempeño relativo de los modelos de aprendizaje automático y así poder juzgar su utilidad.

El siguiente paso es la evaluación de múltiples algoritmos para así poder escoger el mejor modelo a utilizar para cada problema de este trabajo. Para realizar el modelo supervisado se realizó la técnica imputación *iterativa* para los 167 datos faltantes del registro de Rayos Gamma. En la Tabla 2. se resalta el desempeño de los tres principales modelos para el *Problema 1* y el *Problema 2* (todos basados en modelos de árboles de decisión). Los resultados se evalúan en función de las métricas de



Accuracy, *AUC*, *Recall*, *precisión* y *F1*, los cuales presentan métricas similares entre sí. Debido a lo anterior, el modelo que se seleccionó fue el de Extra Trees Classifier para ambos problemas, este presentó los valores más altos en *Accuracy* y en el *F1*.

Tabla 2. Desempeño promedio (con validación cruzada en 10 partes o folds) de los mejores modelos.

Modelo	Accuracy	AUC	Recall	Precision	F1
Problema 1 (Clasificación de 2 litologías)					
Base	0.8700		0.8500	0.8700	0.8600
Extra Trees Classifier	0.9590	0.9864	0.9736	0.9619	0.9676
Hiperparámetros ajustados	0.9329	0.9804	0.9373	0.9557	0.9460
Light Gradient Boosting Machine	0.9550	0.9870	0.9749	0.9549	0.9646
Random Forest Classifier	0.9542	0.9840	0.9749	0.9536	0.9640
Problema 2 (Clasificación de 4 litologías)					
Extra Trees Classifier	0.8614	0.9761	0.8377	0.8635	0.8596
Hiperparámetros ajustados	0.8554	0.9685	0.8219	0.8613	0.8529
Light Gradient Boosting Machine	0.8584	0.9707	0.8342	0.8606	0.8568
Random Forest Classifier	0.8569	0.9711	0.8314	0.8601	0.8546

Al analizar el modelo Extra Trees Classifier más afondo se pudo notar un posible sobreajuste por lo que se realizó un ajuste en los hiperparámetros del modelo¹. Luego de realizar este procedimiento las métricas disminuyen un poco, pero se logra solucionar el problema de sobreajuste.

En la evaluación del modelo se puede observar que el *Problema 1* tiene mejor *Accuracy* (0.93 vs. 0.86) que el *Problema 2* sobre los datos de desarrollo. Lo anterior se debe a que este último presenta más categorías (4 tipos de litologías). Esto se

¹ Los hiperparámetros son configuraciones del modelo que se pueden modificar y pueden tener un efecto positivo o negativo en su precisión. Por defecto se optimiza la *Precision* y evalúa el rendimiento de cada configuración utilizando una validación cruzada de 10 veces (BigData, 2020).



hace evidente en la métrica de evaluación *Recall*, para los datos de desarrollo, donde alcanza valores de 0.94 para el *Problema 1* y 0.82 para el *Problema 2* (Tabla 2). En general la *Precisión* del *Problema 1* alcanza un 96% sobre los datos de desarrollo.

En el *Problema 2*, las métricas disminuyen un poco con respecto al *Problema 1*, sin embargo, siguen siendo unas métricas aceptables. En estas se nota que en la clase Arena arcillosa calcárea y Arcilla arenosa calcárea se presenta un valor alto en la Precisión (0.975 y 0.831 respectivamente) y bajo en el *Recall* (0.675 y 0.754 respectivamente) lo que sugiere que el modelo no detecta la clase muy bien, pero cuando lo hace es altamente confiable. Lo anterior se puede apreciar en la Tabla 3 donde se muestra el reporte de clasificación en detalle para cada problema de este trabajo.

Tabla 3. Reporte de clasificación del modelo Extra Trees Classifier para el *Problema 1* y *Problema 2*. Las métricas se muestran separadas por clases. La columna Support pertenece al número de muestras por clase.

Clases	Precision	Recall	F1	Support
Problema 1 (Clasificación de 2 litologías)				
Arena	0.942	0.953	0.948	341
Arcilla	0.920	0.901	0.910	203
Problema 2 (Clasificación de 4 litologías)				
Arena arcillosa calcárea	0.975	0.675	0.798	117
Arena arcillosa	0.827	0.963	0.890	243
Arcilla arenosa calcárea	0.831	0.754	0.790	65
Arcilla arenosa	0.826	0.838	0.832	142

Así mismo, en la matriz de confusión se observan los valores reales y valores predichos que permite visualizar el desempeño del modelo. Para el *Problema 1*, esta matriz arroja 90% de aciertos en la litología de arcilla y 95% de aciertos en la litología de arena (Figura 2) en los datos de desarrollo. Mientras que para el *Problema 2*, se observan los siguientes porcentajes en los aciertos: 84% en Arcilla



arenosa, 75% en Arcilla arenosa calcárea, 96% en Arena arcillosa y 68% en Arena arcillosa calcárea siendo este el menor porcentaje obtenido (Figura 3). Otras figuras complementarias de la evaluación del modelo pueden verse en los Anexos: Figura S1 a Figura S6.

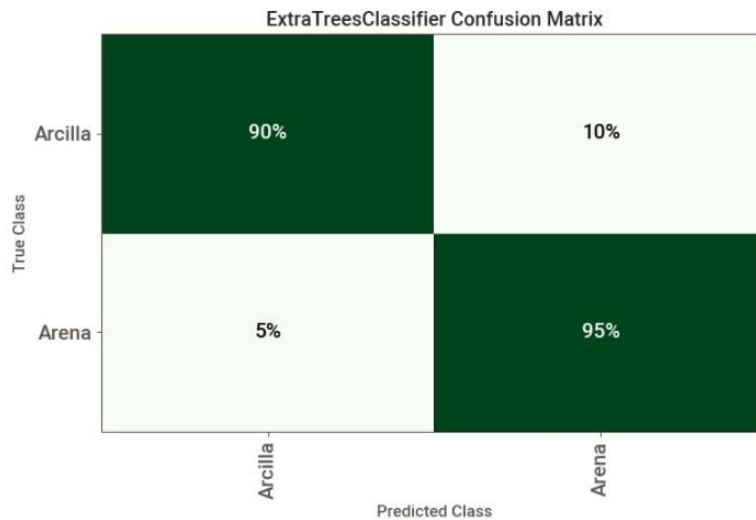


Figura 2. Matriz de Confusión para *Problema 1*. Las predicciones muestran un error menor al 10% para ambas clases identificadas.

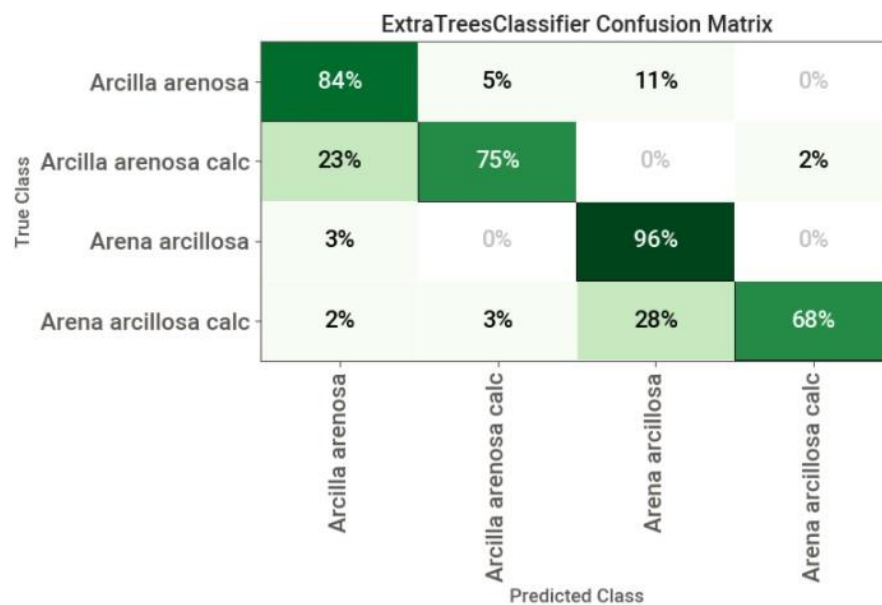


Figura 3. Matriz de Confusión para *Problema 2*. Se observa una visible disminución en los porcentajes de predicción, sobre todo para la clase Arena arcillosa calcárea



El objetivo principal de este estudio es la identificación del tipo de litología de acuerdo a los valores de los registros eléctricos por lo que se revisó cuáles de estos fueron los más importantes para las predicciones, en orden de importancia los registros son (Anexos: Figura S7 y Figura S8):

- Para el *Problema 1*: Registro de Densidad, Registro Rayos Gamma, Registro Neutrón y Registro PEF
- Para el *Problema 2*: Registro Neutrón, Registro PEF, Registro de Densidad y Registro Rayos Gamma.

Luego de tener entrenado el modelo con el pozo Ahuroa-1A para ambos problemas, se evalúa su rendimiento mediante la predicción de la litología en un segundo y tercer pozo, Ahuroa-2 y Ahuroa-2A respectivamente.

Para la evaluación del *Problema 1* los resultados obtenidos se encuentran divididos, ya que en el pozo Ahuroa-2 las métricas de evaluación son menores que en el pozo Ahuroa-2A (Tabla 4), especialmente en el *Recall*.

En el pozo Ahuroa-2 el *Accuracy* es del 91% y se observa como en la litología de Arena las métricas disminuyen con respecto a las de la Arcilla, el *Recall* se encuentra visiblemente bajo y muestra que solo ha identificado correctamente el 41% de las arenas, pero con una *Precision* del 95% (Anexos: Tabla S1).

Tabla 4. Desempeño promedio del modelo probado en los pozos Ahuroa-2 y Ahuroa-2A para el *Problema 1*.

	Accuracy	Precision	Recall	F1-score
Pozo Ahuroa-2	0.91	0.93	0.71	0.76
Pozo Ahuroa-2A	0.94	0.96	0.91	0.93

En cambio, al evaluar el modelo en el segundo pozo (Ahuroa-2A), funciona mejor para ambas litologías, se presenta un *Accuracy* del 94% (Tabla 4) y se está identificando correctamente la arcilla y la Arena (*Recall* de 82% y 100% respectivamente) Anexos, Tabla S1. Por otro lado, la evaluación del modelo en el



Problema 2 muestra un *Accuracy* (0.85) y un *Recall* (0.80) para el pozo Ahuroa-2A, estas métricas son más altas en que en el pozo Ahuroa-2 (Tabla 5).

Tabla 5. Desempeño promedio del modelo probado en los pozos Ahuroa-2 y Ahuroa-2A para el *Problema 2*.

	Accuracy	Precision	Recall	F1-score
Pozo Ahuroa-2	0.76	0.68	0.50	0.54
Pozo Ahuroa-2A	0.85	0.64	0.80	0.66

Para el pozo Ahuroa-2 el modelo presenta problemas para distinguir la categoría de Arcilla arenosa, las métricas para esta clase son demasiado bajas (Anexos: Tabla S2). El *Accuracy* que presenta es del 76%, el modelo no está identificando bien las categorías, la mayoría de los puntos de Arcilla arenosa los está etiquetando como Arcilla arenosa calcárea, lo mismo sucede con la Arena arcillosa calcárea que lo está clasificando como Arcilla arenosa y Arcilla arenosa calcárea. En el pozo Ahuroa-2A el modelo está identificando mejor las litologías de Arcilla arenosa calcárea y Arena arcillosa calcárea (Anexos: Tabla S2), sin embargo, en las otras dos litologías las métricas disminuyen presentando el mismo problema del pozo anterior.

DISCUSIÓN DE RESULTADOS

Este trabajo busca realizar un modelo que se pueda aplicar para la identificación de la litología mediante cuatro registros eléctricos en un pozo de exploración. Los resultados del modelo Extra Trees Classifier muestran que para el *Problema 1* se obtuvo un *Accuracy* del 93%, superando las métricas del modelo base (*Accuracy* del 87%), mientras que en el *Problema 2* el *Accuracy* fue del 86% (en comparación con los modelos de Singh et al. (2020) y Bressan et al. (2020) con un 90% y 85% de *Precision* respectivamente). Sin embargo, el *Problema 2* no presenta comparación con el modelo base.

Para el *Problema 1* las variables que más aportan al modelo son los registros de Densidad y de Rayos Gamma (Anexos: Figura S7). El contenido arcilloso de una roca se ve reflejado en los datos de estos dos registros, el registro de Rayos Gamma



lee la radioactividad asociada a las arcillas y el de Densidad presenta una alta respuesta a los minerales pesados contenidos en las arcillas. Para el segundo problema, el registro Neutron es la variable más importante, pero todas cobran importancia dentro del modelo. Este registro es el que indica el bajo nivel de hidrógeno en los intervalos calcáreos, por esta razón cobra importancia, sin embargo, es ahí donde el modelo está presentando problemas.

En general las métricas de evaluación del modelo en el Problema 1 son mejores que las del *Problema 2*. Esto se comprueba con los resultados de las pruebas realizadas del modelo en cada problema, ya que mostraron que en el *Problema 1* predice mucho mejor la litología, al ser básica, y que en el *Problema 2* al modelo se le dificulta distinguir las diferentes categorías dado que existe mayor complejidad al ser 4 clases las que hay que identificar, lo que indica que al modelo en el *Problema 2* le falta generalizar un poco mejor (Anexos: Figura S4). Estas 4 categorías presentan un margen de diferencia bastante cercano por lo que es posible que el modelo no defina bien los límites de clasificación, si bien es cierto, esto también implica atención por parte del geólogo al realizarlo del modo tradicional (inspección visual).

Por esta razón el *Problema 2* presenta menor porcentaje de acierto en sus predicciones con la clase Arena arcillosa y Arcilla arenosa. Este resultado puede ocurrir en casos donde los tamaños de grano de la arena son difíciles de determinar y las interpretaciones litológicas presentan posibles errores, la arenisca más pequeña termina clasificándose erróneamente en arcilla y eso impacta negativamente en el modelo, de la misma forma el contenido de minerales pesados, medidos por el registro de Rayos Gamma, pueden tener variaciones mínimas que derivan en una difícil clasificación. De igual forma la mayoría de los puntos de Arcilla arenosa el modelo los está identificando Arcilla arenosa calcárea, lo que sugiere que no está identificando bien la característica de ser calcárea, esto tal vez, puede mejorar agregando a las variables de entrada un registro que ayude a la identificación del contenido calcáreo, como por ejemplo un registro de resistividad ya que las rocas compactas poco porosas, como las calizas masivas, poseen



resistividades altas. Es decir, hacer otro juego de registros para el entrenamiento del modelo y así, poder generar mejores resultados.

Finalmente, aunque aún está por encontrarse la diferencia entre ambos resultados en los pozos de prueba el modelo realiza una predicción de clases aceptable y puede utilizarse en registros que presenten estas características. Para esta metodología sería ideal aumentar la cantidad de pozos para el entrenamiento y específicamente entrenarlo con más tipos de litología y así quizá las predicciones sean más exactas. De esta manera podría ser utilizado ampliamente en la industria y los geólogos o cualquier persona que este en el momento de la perforación pueden hacer uso del modelo de clasificación para analizar una gran cantidad de datos de registros de pozos, esto si se tienen datos de LWD (logg while drilling), es decir registros en tiempo real durante la perforación. De lo contrario, se pueden utilizar durante los análisis sedimentológicos, estratigráficos o en los modelos estáticos de un campo para conocer donde pueden estar presentes los reservorios o los sellos lo que también mejora la eficiencia del análisis de datos en la geología del petróleo. Además, se pueden aprovechar las propiedades geofísicas de las rocas sedimentarias adquiridas directamente en campo, con equipos específicos o en laboratorio, reduciendo tiempos y costos en la identificación de litologías. (Bressan et al., 2020)

CONCLUSIONES

El estudio comparó un algoritmo de aprendizaje automático (Extra Trees Classifier) para dos casos diferentes, con dos clases y cuatro clases respectivamente. Los resultados muestran que el *Problema 1* (clasificación de Arena y Arcilla) logró aprender a reconocer en cada pozo la litología preestablecida por el experto humano, y es factible predecir la litología básica (clasificación litológica primaria) a partir de registros eléctricos, lo que permite ayudar al geólogo en sus interpretaciones dando una guía en casos donde la interpretación no es tan obvia o los datos no son tan claros. Adicionalmente permite ahorrar tiempo en algunas tareas rutinarias y ahorrar costos en software especializado.



Para el *Problema 2* (clasificación de Arcilla arenosa, Arcilla arenosa calcárea, Arena arcillosa y Arena arcillosa calcárea) es importante seguir alimentando el entrenamiento y sería más completo si se pudiera cruzar con descripciones litológicas de núcleos para mayor exactitud. En este trabajo se observa que el desafío para la clasificación de la litología está al momento de intentar la identificación de litologías más complejas, que se parecen unas con otras (v. g. Arena arcillosa y Arcilla arenosa), en este caso el modelo no es el más adecuado y se requiere buscar otros tipos de modelos o utilizar una mayor cantidad de datos de registros eléctricos, para disminuir la incertidumbre por errores de interpretación.

Los resultados indican que los métodos de conjunto funcionan bien para la clasificación de litología utilizando datos de registros eléctricos. Los métodos de conjuntos podrían proporcionar información útil para ayudar a distinguir estas clases, ya que realizaron la tarea de clasificación con un *Accuracy* relativamente alto, se deben explorar más características para mejorar su resultado.

ANEXOS




Figura S1. Curva ROC. Para el *Problema 1* el área bajo la curva de las dos litologías está dando 0.97.

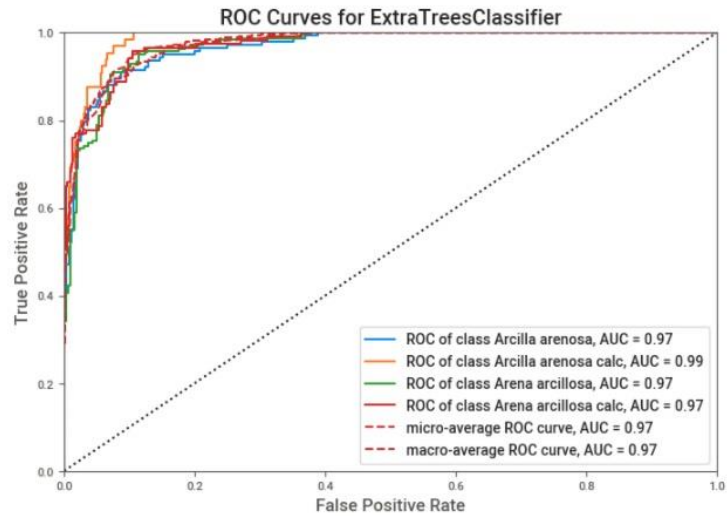


Figura S2. Curva ROC. Para el *Problema 2* el área bajo la curva es de 0.97, menos para la categoría de Arcilla Arenosa calcárea que es de 0.99.




Figura S3. Curva de aprendizaje para el *Problema 1*. La línea de valores de entrenamiento se encuentra muy cerca e incluso dentro de la sombra de la línea valores de testeo. El modelo está generalizando de forma correcta.

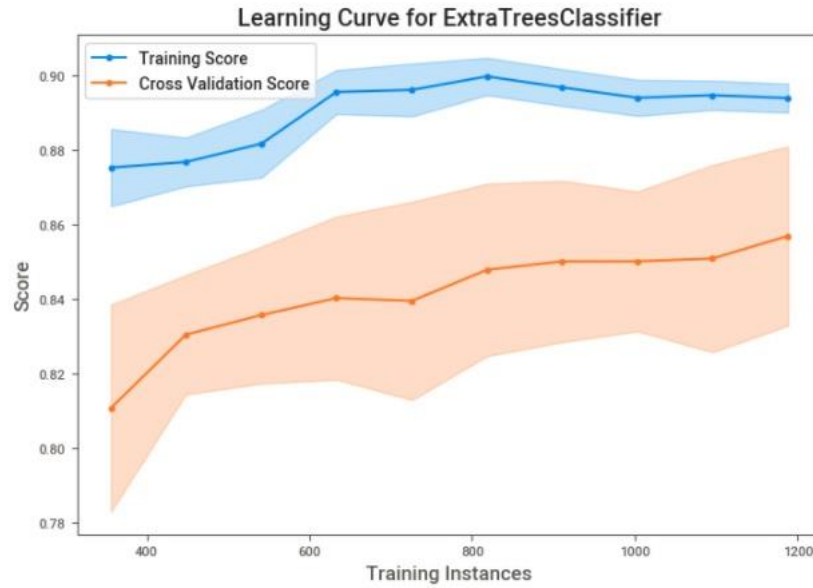


Figura S4. Curva de aprendizaje para el *Problema 2*. Las líneas se están acercando, la línea de valores de entrenamiento todavía no alcanza a entrar a la sombra de la línea valores de testeo. El modelo puede mejorar.

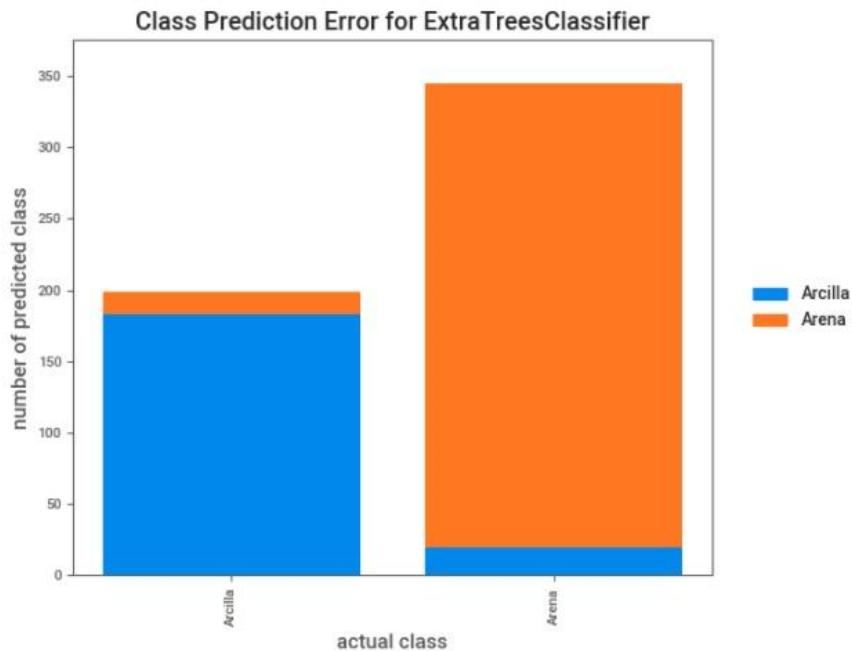


Figura S5. Error de predicción de clase para el *Problema 1*. El modelo parece ser bastante bueno para predecir correctamente las litologías de Arena y Arcilla en función de los registros, sin embargo, en pocas ocasiones no etiqueta como debe ser.

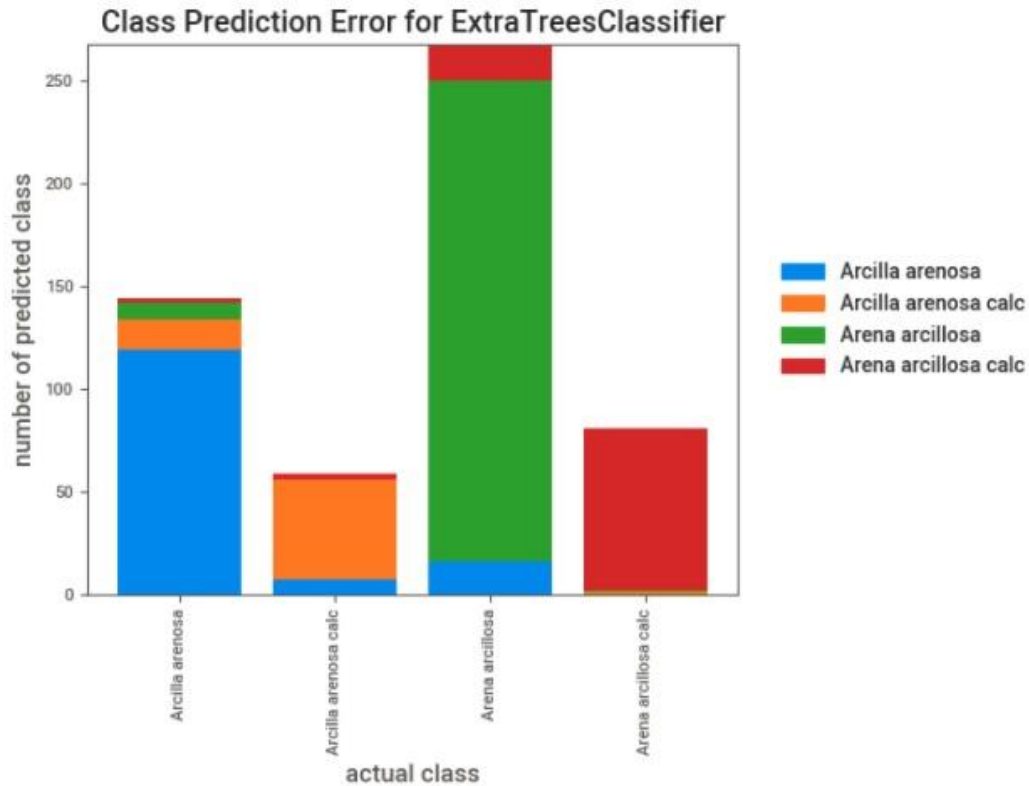


Figura S6. Error de predicción de clase para el *Problema 2*. Aunque el modelo parece ser bastante bueno para predecir correctamente las cuatro litologías en función de los registros utilizados, a menudo el modelo etiqueta incorrectamente confundiéndolas con las otras litologías, por ejemplo, cuando es Arcilla arenosa lo puede confundir con Arcilla arenosa calcárea y Arena arcillosa, en menor proporción Arena arcillosa calcárea.




Figura S7. Las categorías utilizadas para el pronóstico del *Problema 1* se muestran en orden de importancia. La importancia de cada atributo proporciona una puntuación que indica qué tan útil o valiosa fue cada característica dentro del modelo. En este caso la variable menos importante es PEF.




Figura S8. Las categorías utilizadas para el pronóstico del *Problema 2* se muestran en orden de importancia. La importancia de cada atributo proporciona una puntuación que indica qué tan útil o valiosa fue cada característica dentro del modelo. En este caso la más importante fue NEUT, pero todas cobran importancia dentro del modelo.

Tabla S1. Evaluación de métricas. Prueba del modelo para el *Problema 1* en pozo Ahuroa-2 y Ahuroa-2A.

	Precision	Recall	F1-score
Pozo Ahuroa-2			
Arcilla	0.91	1.00	0.95
Arena	0.95	0.41	0.57
Pozo Ahuroa-2A			
Arcilla	0.99	0.82	0.90
Arena	0.92	1.00	0.96

Tabla S2. Evaluación de métricas. Prueba del modelo para el *Problema 2* en pozo Ahuroa-2 y Ahuroa-2A.

	Precision	Recall	F1-score
Pozo Ahuroa-2			
Arcilla arenosa	0.24	0.19	0.21
Arcilla arenosa calcárea	0.82	0.96	0.89
Arena arcillosa calcárea	0.98	0.35	0.51
Pozo Ahuroa-2A			
Arcilla arenosa	0.50	0.67	0.57



Arcilla arenosa calcárea	1.00	0.92	0.96
Arena arcillosa	0.12	0.79	0.21
Arena arcillosa calcárea	0.97	0.82	0.88

REFERENCIAS BIBLIOGRÁFICAS

- Akinyokun, O.C., Enikanselu, P.A., Adeyemo, A.B., Adesida, A., 2009. Well Log Interpretation Model for the Determination of Lithology and Fluid Contents. *Pacific Journal of Science and Technology* 10, 507-517.
- Álzate, G., Branch, J. W., Suárez, O. M., & Vega, C. A. (2006). Correlación de registros entre pozos con redes neuronales artificiales utilizando múltiples curvas o variables registradas. *Boletín de Ciencias de la Tierra* 19, 87-99.
- Baum, A. (11 de octubre de 2020). *Iterative Imputation in PyCaret 2.2*. LinkedIn. <https://www.linkedin.com/pulse/iterative-imputation-pycaret-22-antoni-baum/>
- Bhandari, N. (22 de octubre de 2018). *Extra Trees Classifier*. Medium. <https://medium.com/@namanbhandari/Extra-Trees-Classifier-8e7fc0502c7>
- BigData. (21 de noviembre de 2020). *Una suave introducción a PyCaret para el aprendizaje automático*. <https://topbigdata.es/una-suave-introduccion-a-pycaret-para-el-aprendizaje-automatico/>
- Bressan, T. S., de Souza, M. K., Girelli, T. J., & Junior, F. C. (2020). Evaluation of machine learning methods for lithology classification using geophysical data. *Computers & Geosciences*, 139, 104475. <https://doi.org/10.1016/j.cageo.2020.104475>
- Horrocks, T., Holden, E. J., & Wedge, D. (2015). Evaluation of automated lithology classification architectures using highly-sampled wireline logs for coal exploration. *Computers & geosciences* 83, 209-218. <https://doi.org/10.1016/j.cageo.2015.07.013>.
- Jahdhami, N.A., Anboori, A. (2017). *The Application of Specific Drilling Energy to Identify Overburden Lithological Boundaries and Aid Well Operations – Oman Khazzan Field*. Abu Dhabi International Petroleum Exhibition & Conference, Abu Dhabi, UAE. <https://doi.org/10.2118/188413-MS>.
- Kanfar, R., Shaikh, O.N., Yousefzadeh, M., & Mukerji, T. (2020). Real-Time Well Log Prediction From Drilling Data Using Deep Learning. *ArXiv*, <https://doi.org/10.48550/arXiv.2001.10156>
- McCreery E.B. & Al-Mudhafar W.J. (2017). *Geostatistical Classification of Lithology Using Partitioning Algorithms on Well Log Data - A Case Study in Forest Hill Oil Field, East Texas Basin*.



Conference: 79th EAGE Conference and Exhibition. Paris, France.
<https://doi.org/10.3997/2214-4609.201700905>

Merembayev, T., Kurmangaliyev, D., Bekbauov, B., & Amanbek, Y. (2021). A Comparison of machine learning algorithms in predicting lithofacies: Case studies from Norway and Kazakhstan. *Energies*, 14(7), 1896. <https://doi.org/10.3390/en14071896>

Pillado, C. (2016). Tecnologías para el corte, manipulación, preservación y análisis de núcleos en pozos petroleros. [Tesis de pregrado, Universidad Nacional Autónoma de México] Repositorio Digital de la Facultad de Ingeniería. <http://www.ptolomeo.unam.mx:8080/xmlui/bitstream/handle/132.248.52.100/9546/Tecnologias%20para%20el%20corte%2C%20manipualcion%2C%20preservacion%20y%20 analisis%20de%20nucleos%20en%20pozos%20petroleros..pdf?sequence=1&isAllowed=y>

Singh, H., Seol, Y., and Myshakin, E. (2020). Automated Well-Log Processing and Lithology Classification by Identifying Optimal Features Through Unsupervised and Supervised Machine-Learning Algorithms. *SPE J.* 25. 2778-2800. <https://doi.org/10.2118/202477-PA>

Schlumberger Limited. (1991). *Log interpretation principles/applications*. Schlumberger Educational Services.

Tolios, Ioannis. (s.f.). *Introduction to PyCaret - Build ML models faster w/ less code*. <https://www.learndatasci.com/tutorials/introduction-pycaret-machine-learning/>

Tsanda, A., Bukharev, A., Budenny, S., & Andrianova, A. (2018). Well logging verification using machine learning algorithms. In 2018 International Conference on Artificial Intelligence Applications and Innovations (IC-AIAI) (pp. 1-3). IEEE. <https://doi.org/10.1109/IC-AIAI.2018.8674435>

Xie, Y., Zhu, C., Zhou, W., Li, Z., Liu, X., & Tu, M. (2018). Evaluation of machine learning methods for formation lithology identification: A comparison of tuning processes and model performances. *Journal of Petroleum Science and Engineering*, 160, 182–193. <https://doi.org/10.1016/j.petrol.2017.10.028>.

BigData. (21 de noviembre de 2020). *Una suave introducción a PyCaret para el aprendizaje automático*. <https://topbigdata.es/una-suave-introduccion-a-pycaret-para-el-aprendizaje-automatico/>