



### **Título del proyecto de investigación**

Desarrollo de un sistema de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo la Cira Infantas.

Daniel Andrés Sierra García

Corporación Universitaria Minuto de Dios

Rectoría Virtual

Programa Especialización en Gerencia de Proyectos

septiembre de 2024

## **Proyecto de investigación**

Desarrollo de un sistema de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo la Cira Infantas.

Daniel Andrés Sierra García

Asesor

Phd. Deivi David Fuentes Doria

Corporación Universitaria Minuto de Dios

Rectoría Virtual

Programa Especialización en Gerencia de Proyectos

septiembre de 2024

## Tabla de contenido

Lista de tablas .....	4
Lista Figuras.....	5
Lista Anexos.....	6
INTRODUCCIÓN .....	7
1. PLANTEAMIENTO DEL PROBLEMA DE INVESTIGACIÓN.....	8
1.1 Pregunta de investigación .....	9
1.2 Objetivos .....	9
1.2.1 Objetivo general.....	9
1.2.2 Objetivos específicos.....	9
1.3 Justificación de la investigación.....	10
2. MARCO DE REFERENCIA.....	11
2.1 Marco conceptual.....	11
2.2 Marco teórico .....	15
3. DISEÑO METODOLÓGICO.....	18
3.1 Enfoque.....	18
3.2 Alcance .....	18
3.3 Hipótesis .....	19
3.4 Diseño experimental.....	19
3.5 Definición de la población y tamaño de la muestra .....	20
3.6 Instrumento de recolección de la información.....	22
4. DESARROLLO .....	24
Fase 1: Caracterización de los Datos para el Entrenamiento del Modelo.....	24
Fase 2: Selección del Algoritmo de Inteligencia Artificial.....	26
Fase 3: Ejecución del Algoritmo y Entrenamiento del Modelo.....	27
Fase 4: Evaluación de la Confiabilidad de los Datos.....	28
Fase 5: Análisis de la Hipótesis .....	28
Fase 6: Revisión y Modificación del Diseño Experimental.....	28
Fase 7: Presentación de los Resultados .....	29
Conclusiones.....	32
Recomendaciones.....	33
Referencias .....	34
Anexos .....	36

## Lista de tablas

<b>Tabla 1.</b> Criterio para determinar calidad del cemento .....	19
<b>Tabla 2.</b> Variables extraídas de archivo .LAS .....	24
<b>Tabla 3.</b> Caracterización de intervalos de profundidad según estado de cemento .....	27
<b>Tabla 4.</b> Verificación de resultados con IA .....	29
<b>Tabla 5.</b> Resultado entregado por el algoritmo de IA del estado de la cementación del pozo analizado .....	31

## Lista Figuras

<b>Figura 1.</b> Esquema de la herramienta geofísica que proporciona los registros CBL .....	12
<b>Figura 2.</b> Esquema de la herramienta geofísica que proporciona los registros VDL. ....	12
<b>Figura 3.</b> Ejemplo registro de evaluación de cemento casing 7" amplitud máxima 62 mV. ....	14
<b>Figura 4.</b> Representación esquemática de cómo funciona una neurona artificial.....	17
<b>Figura 5.</b> <i>Simbología para comprender los diseños experimentales.</i> .....	20
<b>Figura 6.</b> Diagrama de Bond Index CIRA4626.....	25
<b>Figura 7.</b> Diagrama de Bond Index superior a 0.8, CIRA4626 .....	25
<b>Figura 8.</b> Diagrama de Amplitud CBL CIRA4626.....	26
<b>Figura 9.</b> Caracterización de color a intervalos según estado de cemento .....	27
<b>Figura 10.</b> Gráfica de variables Vs resultados de algoritmo de IA.....	29

## Lista Anexos

<b>Anexo 1.</b> Tabla amplitud máxima de CBL en tubería libre según diámetro de casing.....	36
<b>Anexo 2.</b> Representación de archivo .LAS con data del pozo evaluado. ....	37
<b>Anexo 3.</b> Programación en Python mediante Google Colab. ....	38

## INTRODUCCIÓN

La evaluación de la cementación en pozos petroleros es un proceso crítico para asegurar la integridad estructural y funcional de los pozos. Los registros de adherencia de cemento, conocidos como Cement Bond Log (CBL), permiten determinar la calidad de la adherencia del cemento al casing (tubería de revestimiento) a lo largo de la profundidad del pozo. Normalmente estos registros son interpretados visualmente por especialistas, quienes analizan las variables representadas de forma gráfica en un registro impreso o una imagen digital. Esta interpretación varía entre profesionales debido a diferentes factores, como la experiencia de la persona, conocimientos técnicos, teóricos, opinión personal y calidad de los datos disponibles.

El análisis tradicional de los registros CBL implica aspectos clave como la amplitud de las ondas acústicas CBL (Cement Bond Log), el registro de densidad variable VDL (Variable Density Log), el tiempo de tránsito TT (Transit Time) y el índice de adherencia (Bond Index). Cada una de estas variables ofrece información valiosa sobre la calidad de la cementación, pero también introduce un grado de complejidad que puede llevar a distintas interpretaciones. Además, factores como la geometría del pozo, eventos durante la perforación, y la presencia de contaminantes pueden afectar estos valores, complicando aún más la interpretación.

La aplicación de la inteligencia artificial (IA) para procesar las variables de la data cruda, surge como una herramienta eficaz para mejorar la precisión y consistencia en el análisis de los registros CBL al permitir procesar grandes volúmenes de datos y analizar múltiples variables simultáneamente, identificando anomalías o desviaciones que podrían ser pasadas por alto en un análisis convencional. En este caso, la inteligencia artificial (IA) permitirá obtener una interpretación rápida y confiable del registro de evaluación de cemento para los pozos del campo La Cira Infantas.

La integración de algoritmos de inteligencia artificial con herramientas como Google Colab mejora significativamente el análisis de los registros de cementación. Google Colab proporciona un entorno de desarrollo ideal para implementar y ejecutar algoritmos de IA, facilitando la realización de análisis complejos de manera eficiente. Además, el soporte nativo para Python en Google Colab permite aprovechar potentes bibliotecas y recursos computacionales, optimizando el proceso de análisis y obteniendo resultados prometedores.

## 1. PLANTEAMIENTO DEL PROBLEMA DE INVESTIGACIÓN

Durante la interpretación de los registros de evaluación de cemento en pozos petroleros, los profesionales enfrentan considerables desafíos para emitir un concepto preciso sobre el estado de cementación de un pozo. Tradicionalmente, este proceso se realiza de forma visual y empírica, analizando registros impresos o imágenes digitales. La interpretación de estos registros depende en gran medida de la experiencia individual del profesional, sus conocimientos técnicos y teóricos, así como de la disponibilidad y la calidad de los datos del pozo. Esta subjetividad en el análisis puede llevar a interpretaciones diversas e inconsistentes entre distintos evaluadores, lo que a su vez puede resultar en la toma de decisiones erróneas (Schlumberger, 2024) (Topes Rojas et al., 2017).

La incorrecta evaluación del estado de la cementación puede llevar a fallas en la integridad del pozo, requiriendo intervenciones adicionales que incrementan los costos operativos. Además, la falta de precisión en la evaluación puede poner en riesgo la seguridad de las operaciones, con consecuencias potencialmente graves para el medio ambiente y la producción (Schlumberger, 2024). Actualmente se cuenta con herramientas especializadas, como el software Kappa Emeraude, que permiten una mejor perspectiva del estado de la cementación al procesar diversas variables y datos sobre la construcción del pozo, su uso no está ampliamente extendido ni es suficiente para abordar todos los escenarios que pueden presentarse en los registros de cementación (KAPPA, 2024).

En este contexto, la inteligencia artificial (IA) se proyecta como una alternativa viable para realizar los análisis de la cementación. La IA tiene la capacidad de procesar grandes volúmenes de datos y analizar simultáneamente múltiples variables, identificando patrones y correlaciones que podrían ser difíciles de detectar en un análisis manual convencional (Ogunkunle et al., 2021; Obafemi et al., 2020). La implementación de IA en el análisis de los registros CBL podría no solo mejorar la precisión en la evaluación de la cementación, sino también reducir los costos y tiempos asociados con las operaciones de pozo.

Este proyecto de investigación tiene como objetivo integrar un sistema basado en IA para optimizar el análisis de los registros de evaluación de cemento en los pozos petroleros del campo La Cira Infantas utilizando las tecnologías avanzadas como la IA. De esta forma, transformar el proceso de evaluación de la cementación en los pozos, ofreciendo resultados precisos a través herramientas que están a la vanguardia de la tecnología, pudiendo aumentar la eficiencia

operativa y asegurar decisiones más informadas y confiables en la industria petrolera (World Energy Trade, 2023).

## **1.1 Pregunta de investigación**

¿Cómo integrar las nuevas tecnologías de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo la Cira Infantas?

## **1.2 Objetivos**

### **1.2.1 Objetivo general.**

Utilizar un sistema basado en inteligencia artificial para analizar registros de evaluación de cemento en pozos petroleros del campo La Cira Infantas.

### **1.2.2 Objetivos específicos.**

Seleccionar un algoritmo de inteligencia artificial adecuado para el análisis de registros de evaluación de cemento en pozos petroleros.

Implementar un sistema de inteligencia artificial capaz de analizar los registros de evaluación de cemento de manera automatizada.

Validar la eficacia del sistema desarrollado mediante pruebas en registros reales de pozos petroleros del campo La Cira Infantas.

Documentar el desarrollo e implementación del sistema, proporcionando una guía para su uso en la industria.

### 1.3 Justificación de la investigación

El uso de inteligencia artificial en la evaluación de registros de cemento en los pozos petroleros del campo La Cira Infantas puede proporcionar beneficios significativos, como mejorar la eficiencia, aumentar la precisión, reducir errores y optimizar los tiempos de operación. La inteligencia artificial al tener la capacidad de analizar gran cantidad de datos con una precisión y alta velocidad permitirá obtener una evaluación del registro más confiable de la calidad de la cementación, al identificar zonas de buen cemento y anomalías como pueden ser zonas mal cementadas, canalización de cemento, identificar tubería libre entre otros. Acelerar el proceso de análisis mediante IA, permitirá a los ingenieros dedicar más tiempo a otras tareas críticas. Esto puede resultar en una mayor eficiencia operativa y en la reducción del tiempo necesario para tomar decisiones relacionadas con el completamiento y la producción del pozo.

Según Russell y Norvig (2020) en su obra *Artificial Intelligence: A Modern Approach*, la IA es capaz de automatizar procesos complejos, mejorar la precisión de los resultados y reducir el sesgo humano, lo que es crucial en el análisis de registros de cementación. Por su parte autores como (LeCun et al., 2015) en su artículo *Deep Learning* publicado en *Nature*, han demostrado cómo las redes neuronales profundas pueden modelar problemas complejos con alta precisión, lo que es directamente aplicable al análisis de registros CBL y VDL en pozos petroleros del campo la Cira Infantas.

World Energy Trade considera que la inteligencia artificial es un factor transformador para el sector del petróleo y el gas, utilizándose para disminuir los costos operativos, mejorar la sostenibilidad y agilizar los procesos. Según un estudio de mercado realizado por Mordor Intelligence, se proyecta que el uso de la IA en este mercado crecerá a una tasa del 10,81% entre 2022 y 2027 (World Energy Trade, 2023). Utilizar técnicas avanzadas de inteligencia artificial para desarrollar un sistema de análisis de registros de evaluación de cemento se justifica en la necesidad de mejorar la eficiencia y precisión en la interpretación de estos registros.

Actualmente, el proceso de interpretación puede ser laborioso y propenso a errores humanos, lo que puede afectar la calidad de las decisiones que se toman en pozo. Al aplicar técnicas de inteligencia artificial, se busca automatizar y optimizar este proceso, permitiendo una evaluación más rápida, precisa y fiable de los datos. Esto no solo mejorará el análisis de los registros de cased hole, sino que también puede reducir costos y tiempos de proyecto. En última instancia, el proyecto busca contribuir al avance tecnológico y la competitividad en la industria petrolera mediante la implementación de soluciones innovadoras basadas en inteligencia artificial

además de ser una solución tecnológica avanzada que está a la vanguardia del desarrollo de la industria global.

## 2. MARCO DE REFERENCIA

### 2.1 Marco conceptual

El análisis de la calidad del cemento en pozos petroleros es esencial para garantizar la integridad estructural del pozo y prevenir la migración de fluidos entre formaciones. Las principales variables de los registros de evaluación de cemento son CBL (*cement bond log*) que quiere decir registro de adherencia de cemento, es la variable que nos indica como su nombre lo dice cuanto cemento esta adherido al casing el VDL (*variable density log*) que significa registro de densidad variable e indica cuanto cemento hay presente entre el casing y el hueco, y el Bondix (*Bond Index*) es una medida cuantitativa crítica que se utiliza para evaluar la calidad de la adherencia del cemento al casing. Las tres variables antes mencionadas son registros que se adquieren a través de ondas sónicas, que son procesadas a través de un sistema de adquisición de datos, en donde Warrior Data Acquisition Systems (Scientific Data Systems, Inc., 2024) es uno de los más utilizados en la industria.

Según (Topes Rojas et al., 2017) el objetivo principal de la medición del CBL es identificar las áreas del pozo donde la cementación presenta problemas. Cuando se combina con el VDL, se obtiene una representación más detallada de la calidad del cemento en el espacio anular entre el casing y la formación. Este registro se genera a partir de la misma señal acústica utilizada en el CBL, pero ofrece una representación visual continua de la densidad del cemento. El VDL permite identificar zonas de baja calidad de cemento o la presencia de canales, que podrían comprometer el aislamiento zonal, lo cual es crucial para evitar la migración de fluidos no deseados entre formaciones, este análisis ha sido, durante muchos años, el método principal para evaluar la calidad de la cementación.


Las herramientas se componen de dos secciones: acústica y electrónica. El registro acústico mide la adherencia del cemento al casing a lo largo de la profundidad del pozo. Este registro se obtiene mediante la emisión de ondas acústicas desde un transmisor las cuales son leídas en dos receptores. El transmisor emite un pulso omnidireccional a una frecuencia relativamente baja, entre 10Hz y 20 KHz, que induce una vibración longitudinal en la tubería de revestimiento (casing). La onda emitida viaja a través de la tubería y es leída por los sensores que están ubicados a 3ft y 5 ft (0,91m y 1,52 metros) del transmisor. El primer receptor (3ft),

censa la variable CBL (figura 1) y el segundo sensor que está a 5 ft registra la variable VDL (figura 2). Por parte la electrónica de la herramienta toma el primer arribo de la señal de CBL (3ft) y mide su amplitud, ahora para la señal de VDL toma todo el tren de pulsos recibidos, y los transmite junto a otras variables al sistema de adquisición en superficie para ser procesados y posteriormente registrados en una base de datos.

La amplitud de la onda acústica recibida es inversamente proporcional a la calidad de la adherencia del cemento al casing; una alta amplitud indica una pobre adherencia, mientras que una baja amplitud sugiere una buena adherencia (Schlumberger, 2024)

**Figura 1.** Esquema de funcionamiento de la sección de registros CBL.

▪ Amplitud de CBL




Nota. Fuente (ACIPET, 2020)

El perfil de cementación CBL mide la amplitud del primer arribo o de la primera cresta positiva de la onda sónica producto del reflejo al impactar el casing. Esta amplitud es un indicador clave, ya que su atenuación permite determinar la calidad de la adherencia del cemento a la tubería de revestimiento. Este método es útil para identificar áreas donde hay ausencia de cemento o baja densidad. Para ilustrar este concepto, se podría hacer una analogía con el sonido producido al golpear una campana metálica con el badajo. Cuando la campana es golpeada libremente, produce un sonido claro y resonante. Sin embargo, si se sostiene la campana con las manos, el sonido se amortigua, reduciendo significativamente su volumen.

**Figura 2.** Esquema de funcionamiento de la sección de registros VDL.

■ VDL (Variable Density Log) / MSG (Microsismograma)



Nota. Fuente (ACIPET, 2020).

La variable CBL, que se mide en milivoltios, decibeles por pie (db/ft), o a través del Índice de Adherencia (bond index), refleja que la atenuación de la señal incrementa de forma progresiva a lo largo de las distintas etapas del fraguado del cemento, alcanzando su valor máximo cuando el cemento ha fraguado completamente. Durante el proceso de asentamiento, tanto la velocidad como la amplitud de las señales sufren variaciones significativas. Por este motivo, Schlumberger (2024) recomienda no realizar el registro CBL hasta pasadas 24-36 horas desde la finalización del trabajo de cementación, con el fin de obtener resultados precisos y confiables. Este lapso de espera asegura que el cemento haya alcanzado la rigidez adecuada, minimizando la posibilidad de obtener lecturas inexactas o prematuras que podrían comprometer la evaluación de la integridad del pozo.

Las mediciones se realizan configurando una ventana electrónica para evaluar la amplitud de la señal recibida en los receptores ubicados a 3ft y 5 ft. Generalmente, esta ventana se ajusta para medir la amplitud de la primera onda o primer arribo. Se da por entendido que la señal proveniente del revestimiento llegará antes que cualquier otra. Dado que la intensidad de la señal es función del material presente en el espacio anular (el espacio entre el tubo y la pared del pozo), el registro de amplitud del primer ciclo permite evaluar la calidad de la cementación. Cuanto mayor sea el relleno, que este casi es la cantidad de cemento en el espacio anular, más débil será la señal que llega al receptor, y por lo tanto, la amplitud será menor. Con base en lo anterior, la amplitud de la variable CBL se clasifica de la siguiente manera:

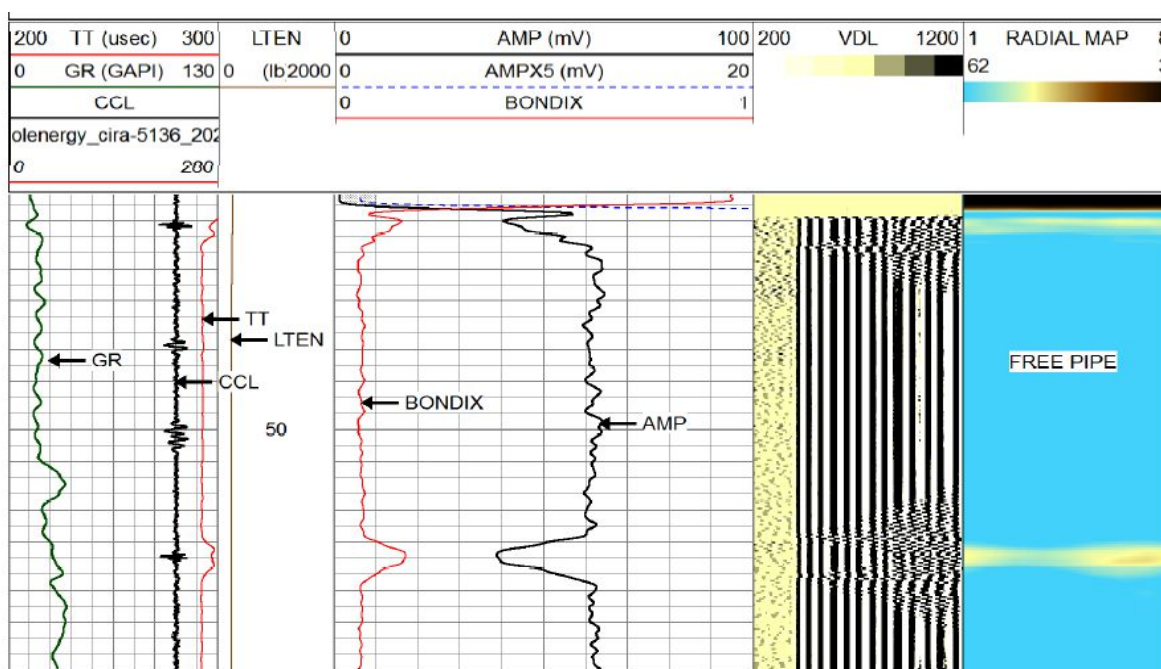
Amplitudes bajas (menor al 10% del máximo posible): Indican una buena adherencia y una cementación efectiva.

Amplitudes medias (entre el 10% y el 20% del máximo posible): Indican una adherencia intermedia, que puede requerir una evaluación más detallada para determinar su impacto en el aislamiento hidráulico.

Amplitudes altas (mayor al 20% del máximo posible): Sugieren una pobre adherencia, lo que puede resultar en una cementación deficiente y la necesidad de intervenciones correctivas.

Basado en lo anterior, la amplitud del CBL es máxima cuando no hay cemento, o dicho de otro modo, cuando se tiene la tubería libre (Figura 4):

**Figura 3.** Ejemplo registro de evaluación de cemento casing 7" amplitud máxima 62 mV.



Nota. El registro se presenta profundidad (ft) vs valor de la variable procesada.

La interpretación cuantitativa se lleva a cabo utilizando el Índice de Adherencia (Bond Index), calculado como se observa en la ecuación 1. Este índice ofrece una evaluación cuantitativa de la calidad de la cementación basándose exclusivamente en el registro CBL y está linealmente relacionado con el porcentaje de cemento adherido en la superficie del casing.

El *Bond Index* se define matemáticamente como:

*Ecuación 1.*

$$Bond\ Index = \frac{A_{max} - A_{observed}}{A_{max} - A_{mín}}$$

Donde:

- $A_{max}$ : Es la amplitud máxima de la señal en un casing libre (sin cemento).
- $A_{observed}$ : Es la amplitud registrada durante la evaluación.
- $A_{mín}$ : Es la amplitud mínima que corresponde a un casing completamente adherido al cemento.

Un *Bond Index* elevado indica una buena adherencia del cemento al casing, lo que sugiere una cementación efectiva. Por otro lado, un índice bajo puede indicar problemas en la adherencia, lo que podría comprometer la integridad del pozo y requerir intervenciones correctivas (Schlumberger, 2024).

## 2.2 Marco teórico

La implementación de la inteligencia artificial (IA) en la evaluación de registros de cemento en los pozos petroleros, como los del campo La Cira Infantas, requiere una integración cuidadosa de los principios técnicos tanto de la evaluación de registros como de la IA. Este marco teórico tiene como objetivo establecer una base sólida para la aplicación exitosa de la IA en la interpretación de registros de evaluación de cemento, abordando tanto los aspectos tecnológicos de la inteligencia artificial como las variables específicas que se encuentran en los registros de cemento.

Según Russell y Norvig (2020), la inteligencia artificial se define como la capacidad de un sistema computacional para realizar tareas que típicamente demandan habilidades cognitivas humanas, como toma de decisiones o el reconocimiento de patrones basados en datos. La inteligencia artificial se divide en tres categorías principales: Inteligencia Artificial Estrecha (ANI), Inteligencia Artificial General (AGI) y Superinteligencia Artificial (ASI). Según Dinesh et al. (2024), la ANI es la forma más común de IA en uso actualmente. Este tipo de IA se desarrolla para realizar tareas específicas, como jugar ajedrez, predecir ventas o analizar datos en áreas específicas. La ANI es particularmente útil en la evaluación de registros de cemento, ya que se

puede entrenar para identificar tendencias y detectar variaciones en grandes volúmenes de datos de registros CBL, lo que la convierte en una herramienta esencial para este propósito.

Los algoritmos de IA son fundamentales para la interpretación precisa de los registros de cementación. (Goodfellow et al., 2016) en su obra *Deep Learning* destacan el uso de redes neuronales profundas para el modelamiento de problemas complejos, lo que es crucial para el análisis de registros de cementación donde las señales acústicas pueden ser interpretadas para inferir la calidad del cemento. Entre los algoritmos más relevantes para esta aplicación se incluyen:

*Aprendizaje Automático*: Utilizado para identificar patrones en los datos de registros, mejorando la precisión del análisis a medida que se procesan más datos históricos.

*Máquinas de Vectores de Soporte (SVM)*: Eficientes para clasificar los datos en categorías como "buena adherencia" o "mala adherencia" basadas en los registros CBL y VDL.

*Redes Neuronales Artificiales (ANN)*: Imitan el funcionamiento del cerebro humano, permitiendo la evaluación de relaciones no lineales en los datos de cementación.

(Ogunkunle et al., 2021) demostraron en su investigación cómo los algoritmos de bosque aleatorio y las redes neuronales artificiales pueden ser utilizados para predecir propiedades geomecánicas a partir de registros de pozo, lo que es directamente aplicable al análisis de registros CBL en el campo La Cira Infantas. Estos modelos permiten realizar predicciones precisas sobre la calidad del cemento en función de los datos de entrada, mejorando la capacidad de los ingenieros para tomar decisiones informadas sobre la necesidad de intervenciones adicionales en la cementación.


Las redes neuronales artificiales (ANN) son una clase de modelos de IA que han sido particularmente efectivos en la interpretación de registros de cementación. Según (Obafemi et al., 2020), las ANN utilizan una estructura de múltiples capas de neuronas interconectadas, lo que les permite aprender a partir de ejemplos y mejorar sus predicciones con el tiempo. A diferencia de los algoritmos de computación convencionales, que siguen un conjunto fijo de reglas, las ANN pueden adaptarse a nuevas situaciones a través del aprendizaje, lo que las hace ideales para la interpretación de datos complejos y variados como los encontrados en registros CBL y VDL.

Las ANN reciben un conjunto de insumos (por ejemplo, datos acústicos de CBL), que luego se ponderan y se procesan a través de una función de transferencia para generar una salida. Esta salida podría ser, por ejemplo, una predicción sobre la calidad del cemento en una sección específica del pozo. La capacidad de las ANN para procesar gran cantidad de datos y aprender de estos datos las convierte en una herramienta poderosa para mejorar la precisión de las evaluaciones de cementación, reduciendo la dependencia en la interpretación manual y subjetiva.

Según la literatura de la publicación “Caracterización de canales de turbiditas en aguas profundas y lóbulos de abanicos submarinos mediante inteligencia artificial; Estudio de caso del campo Frem en alta mar en el delta del Níger” (Obafemi et al., 2020), Las redes neuronales artificiales (RNA) utilizan algoritmos que procesan la información de manera que intentan imitar el cerebro humano. A diferencia de los algoritmos de computación convencionales que siempre siguen los mismos pasos programados independientemente de los datos de entrada, las redes neuronales aprenden por prueba, utilizando un conjunto de entradas, y por lo tanto no están programadas para realizar una tarea específica.

Las ANN funcionan como redes neuronales biológicas que están formadas por miles de millones de neuronas interconectadas, construyendo redes de información extremadamente complejas. Las ANN utilizan el mismo principio basado en neuronas artificiales, con una configuración más sencilla. Las neuronas artificiales son unidades de procesamiento interconectadas en una red de comunicación compleja que trabajan juntas para resolver una tarea específica (figura 5 ). Reciben un conjunto de insumos, que pueden provenir de múltiples fuentes, que luego se multiplican por un peso. El resultado de la ponderación se suma y se pasa a través de una función de transferencia que devuelve una o más salidas.

**Figura 4.** Representación esquemática de cómo funciona una neurona artificial.



### **3. DISEÑO METODOLÓGICO**

#### **3.1 Enfoque**

Se llevará a cabo un enfoque de investigación cuantitativo, con el fin de tener conclusiones sólidas estadísticas de la información recopilada; lo anterior debido a que la variable estudiada se encuentra en un rango de valores definido en las bases de datos .db del registro de evaluación de cemento tomado en cada pozo. De tal manera, que una conclusión basada en datos numéricos resultara más efectiva para tomar decisiones importantes en el análisis de cada pozo con relación al estado de la cementación.

Todo esto contando con instrumentos como la inteligencia artificial para análisis de la variable vs profundidad del pozo, que produzca datos y estadísticas concretas con el fin de analizar los factores más relevantes, obteniendo resultados confiables. El análisis de los resultados será específico para cada pozo y para ello se tomará una muestra representativa de la data de 2 pozos para entrenar el modelo de IA, y de esta forma generar el menor error de la variable a estudiar.

#### **3.2 Alcance**

Para la implementación del sistema de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo la Cira Infantas, se realizará una investigación de alcance correlacional - descriptivo.

El primero permitirá analizar la variable CBL (cement bond log) vs profundidad del pozo, mediante algoritmos de análisis de estadística que nos proporcione la inteligencia artificial, teniendo en cuenta el máximo valor de la variable CBL (depende del diámetro del pozo y la tubería) Anexo 1. El porcentaje del valor de CBL obtenido en el intervalo de profundidad nos permitirá conocer el estado del cemento, es decir determinar si hay buen cemento, regular cemento o mal cemento según se muestra en la tabla 1.

El segundo, referente a lo descriptivo, se realizará con base a los resultados obtenidos de la investigación correlacional, específicamente en los rangos en que se encuentre el porcentaje de CBL obtenido, que permitirán la contextualización para el establecimiento de conclusiones del estado de la cementación de cada pozo evaluado.

**Tabla 1. Criterio para determinar calidad del cemento**

Amplitud máxima en tubería libre	Calidad del cemento
$CBL < 10\%$	Buen cemento
$10\% > CBL < 20\%$	Regular cemento
$CBL > 20\%$	Mal cemento

Nota. CBL variable independiente.

### 3.3 Hipótesis

Hipótesis alterna  $H_A$ :

A través de algoritmos de inteligencia artificial se puede determinar el estado de la cementación en diferentes intervalos de profundidad de cada pozo evaluado del campo la Cira Infantas.

*Variable dependiente: CBL de la base de datos del pozo.*

*Variable independiente: Estado de cementación del pozo.*

Hipótesis Nula  $H_0$ :

A través de algoritmos de inteligencia artificial no se puede determinar el estado de la cementación en diferentes intervalos de profundidad de cada pozo evaluado del campo la Cira Infantas.

### 3.4 Diseño experimental

El diseño de investigación que se usará para el proyecto se basa en los recursos disponibles, hipótesis y el planteamiento del problema, el cual nos permitirá integrar las nuevas tecnologías de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo la Cira Infantas. Según lo anterior el diseño de investigación para el presente proyecto será Pre experimental.

**Figura 5. Simbología para comprender los diseños experimentales.**

A	Asignación al azar o aleatoria. Cuando aparece quiere decir que los sujetos o casos han sido asignados a un grupo de manera aleatoria (aleatorización). Si no aparece significa que los grupos <b>no</b> fueron asignados al azar. También se suele utilizar la "R" de <i>randomization</i> (aleatorización en inglés), como se hace en el capítulo 5 del Centro de recursos en línea.
G	Grupo de casos o sujetos (G <sub>1</sub> , grupo 1; G <sub>2</sub> , grupo 2; etcétera).
X	Tratamiento, estímulo, intervención o condición experimental: Presencia de algún nivel o modalidad de la variable independiente. Es un grupo experimental.
(M)	Una medición de los sujetos o casos de un grupo (prueba, cuestionario, observación, etc.). Si aparece antes del estímulo o tratamiento, se trata de una preprueba (previa al tratamiento). Si aparece después del estímulo se trata de una posprueba (posterior al tratamiento).
—	Ausencia de estímulo (nivel cero en la variable independiente). Indica que se trata de un grupo de control o testigo.
↻	Comparación de mediciones (vertical entre mediciones previas al estímulo o posteriores y horizontal entre una medición previa al estímulo y una posterior)

Nota. Fuente (Hernández & Mendoza)

La investigación pre-experimental se realizará con un estudio de caso de una sola medición de la siguiente manera:



Donde:

G corresponde a la base de datos con la variable independiente CBL del pozo a evaluar.

X algoritmo suministrado por inteligencia artificial.

M verificación del estado del cemento del pozo en un intervalo de profundidad.

### 3.5 Definición de la población y tamaño de la muestra

Se determina como marco muestral la base de datos del pozo a analizar (Anexo 2), y el objeto de estudio es la variable independiente CBL. Para la selección de la muestra se determina los siguientes parámetros

**Tamaño de la población:** Población finita, se puede determinar el número de muestras en la base de datos.

**Variable de estudio:** Variable independiente CBL

**Muestra piloto:** Se considera determinar una muestra piloto con el 5% de la data de la variable independiente debido a que cada base de datos es particular y específica a cada pozo. Es de aclarar la data presenta 2 muestras/pie y un registro completo en promedio tiene 3000 ft registrados. Conocer el valor de la desviación estándar nos permite más adelante determinar el tamaño de la muestra de la variable independiente a analizar.

Ecuación 2:

$$S = \sqrt{\frac{\sum(X - \bar{x})^2}{n - 1}}$$

Donde:

S: Desviación estándar de la muestra piloto

n: Número de muestras de la muestra piloto

x: Valor o medida de la variable CBL

$\bar{x}$ : Promedio de la medida de la variable CBL

**Nivel de confianza (Z):** se tomará el 95% del nivel de confianza basándose en que el muestreo por pie de registro es alto.

**Error (E):** Para el análisis de la calidad de cemento se estima que un nivel de error del 5% es aceptable.

**Muestra representativa:** La fórmula estadística apropiada ya que se conoce el total de las muestras por cada base de datos es.

Ecuación 3.

$$n = \frac{S^2}{\frac{E^2}{Z^2} + \frac{S^2}{N}}$$

Donde:

n: tamaño de la muestra por estimar.

S: desviación estándar de la muestra piloto.

E: error de estimación.

Z: nivel de confianza.

N: número total de la población objeto de estudio.

### **3.6 Instrumento de recolección de la información**

El instrumento de medición que se utilizará para la recolección de la información será la observación, comenzando con el estudio de la variable y determinando el medio de observación, que se llevará a cabo a través de diferentes herramientas como archivos de texto (.txt) y hojas de cálculo (.xlsx) para registrar la información. Este proceso se dividirá en tres fases: en la Fase 1, se realizará la recolección de la información mediante la revisión del problema, los objetivos y la hipótesis; en la Fase 2, se llevará a cabo la observación, revisando las bases de datos y la información relevante de los pozos objeto de estudio; y en la Fase 3, se realizará la finalización del proceso con la revisión de la información registrada para asegurar que corresponda con los objetivos de la investigación.

Los datos recolectados para este proyecto provienen de los registros de evaluación de cemento en pozos petroleros del campo La Cira Infantas. Los datos se categorizarán en tres grupos principales para una mejor organización y comprensión: datos crudos de registros de cemento (CBL, VDL y BondIX), datos mecánicos del pozo y datos históricos y de referencia. Los datos crudos de registros de cemento fueron obtenidos directamente de las herramientas de registro dentro del pozo utilizando el sistema de adquisición de datos Warrior Data Acquisition Systems de la compañía Scientific Data Systems, Inc., y el software "Warrior Data Acquisition Software" (Scientific Data Systems, Inc., 2024).

Los registros son tomados de abajo hacia arriba dentro del pozo con el fin de garantizar la velocidad de registro y tensión de cable constantes durante todo el intervalo. Las amplitudes de las ondas acústicas fueron registradas de manera continua y almacenadas en un archivo .DB, para su posterior extracción y análisis, la data fue exportada a un archivo .LAS, el cual puede ser abierto fácilmente con un editor de texto (.txt). Durante el proceso de limpieza, se aplicaron filtros para eliminar el ruido de los datos crudos, y los registros fueron revisados para corregir cualquier error de medición evidente. Es importante tener en cuenta que antes de realizar el registro, la herramienta fue calibrada en un tubo de prueba, según los parámetros específicos del fabricante y las variables del pozo a registrar.

En cuanto a la información sobre el estado mecánico y la construcción del pozo, incluyendo la profundidad y el diámetro del casing, fue recopilada a partir de informes de ingeniería y registros de construcción de cada pozo, y se realizó un proceso de validación cruzada utilizando múltiples fuentes para asegurar la precisión de estos datos. Además, los datos históricos de cementación y los registros anteriores de CBL y VDL del pozo, así como de pozos similares en el campo La Cira Infantas, fueron recopilados mediante acceso a bases de datos internas que incluyen información de más de 100 pozos y archivos históricos de la empresa operadora.

Para el tratamiento y análisis de los datos recolectados, se empleará el “Warrior Data Acquisition Software” para exportar los datos a formatos .LAS o .CSV, los cuales posteriormente serán analizados en EXCEL con la ayuda del software Jamovi. Las variables serán codificadas y etiquetadas claramente para facilitar el análisis. En casos donde haya datos faltantes, se utilizarán métodos de imputación, como asignar cero a valores negativos o el promedio de las mediciones cercanas, para completar los valores faltantes. Finalmente, se realizarán análisis descriptivos iniciales, gráficos de dispersión, pruebas de hipótesis utilizando herramientas de inteligencia artificial como Google Colab y/o DataRobot, para validar las hipótesis planteadas en el diseño metodológico.

### **Preparación de los Datos:**

**Nombres de Variables:** Cada variable debe ser etiquetada claramente. Por ejemplo, "Profundidad", "Amplitud CBL", "Bondindex", "Diámetro del Casing".

**Tipos de Datos:** Las variables fueron asignadas a tipos de datos apropiados (numérico-continuo) para facilitar el análisis.

**Datos Faltantes:** Se utilizará métodos de imputación para manejar datos faltantes. Por ejemplo, cero para valores negativos, el promedio de las mediciones cercanas para completar valores faltantes en los registros de amplitud.

#### 4. DESARROLLO

Para aplicar los algoritmos de inteligencia artificial en el análisis de los registros de evaluación de cemento en pozos petroleros del campo La Cira Infantas, se seguirá un enfoque cuantitativo con un alcance correlacional-descriptivo. Este método de análisis se desarrollará en siete fases, detalladas a continuación, fase 1 que comprende la caracterización de los datos para el entrenamiento del modelo, fase 2 para selección del algoritmo de inteligencia artificial, en la fase 3 ejecución del algoritmo y entrenamiento del modelo, fase 4 donde se realizara la evaluación de la confiabilidad de los datos, fase 5 comprende análisis estadístico de la hipótesis, fase 6 revisión y modificación del diseño experimental, y por último la fase 7 donde se presenta los resultados de Inteligencia Artificial.

##### Fase 1: Caracterización de los Datos para el Entrenamiento del Modelo

Se procede a realizar un análisis descriptivo de los datos obtenidos de la variable independiente CBL y Bondix. Esto incluirá el cálculo de las medidas estadísticas, media, mediana, desviación estándar, variación estándar, y la generación de gráficas y puntuaciones que permitan una comprensión detallada de los datos antes del entrenamiento del modelo. En la plataforma de *Google Colab* se realiza la programación para el cargue del archivo .LAS o .TXT, se organiza la data, promueve el encabezado, convierte las columnas de datos tipo object a tipo float, convierte en cero los valores negativos de las variables AMP3FT(cbl) y BONDIX.

**Tabla 2.** Variables extraídas de archivo .LAS

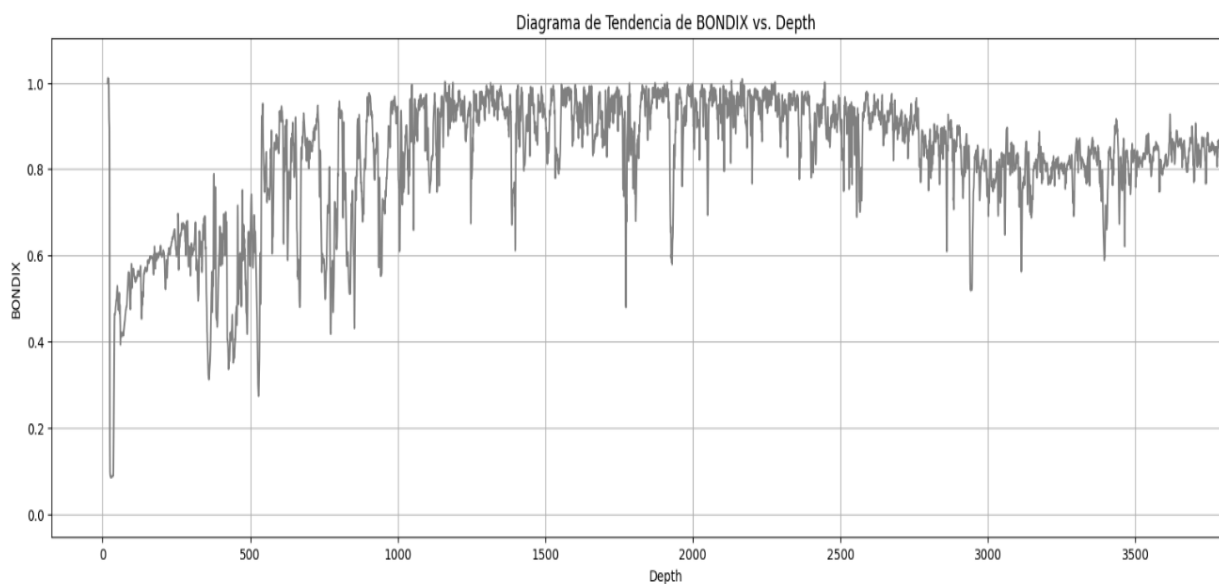
0	Depth	LTEN	GR	TT3FT	CCL	AMP3FT	BONDIX
7571	17.0	393.5346	17.3916	1234.8119	0.1117	1.0040	0.9991
7570	17.5	393.5346	15.9697	1236.3551	-0.0110	0.9704	1.0068
7569	18.0	378.6776	15.9868	1225.4469	0.0299	0.9572	1.0099
7568	18.5	373.7253	16.5380	1207.8596	0.0735	0.9631	1.0085
7567	19.0	375.7063	14.7087	1169.9841	-0.4761	0.9557	1.0103
...	...	...	...	...	...	...	...
5	3800.0	1147.2771	-999.2500	-999.2500	-999.2500	0.0000	0.0000
4	3800.5	1061.1068	-999.2500	-999.2500	-999.2500	0.0000	0.0000
3	3801.0	866.9760	-999.2500	-999.2500	-999.2500	0.0000	0.0000
2	3801.5	867.9665	-999.2500	-999.2500	-999.2500	0.0000	0.0000
1	3802.0	883.8139	-999.2500	-999.2500	-999.2500	0.0000	0.0000

[7571 rows x 7 columns]

Nota. Fuente Google Colab

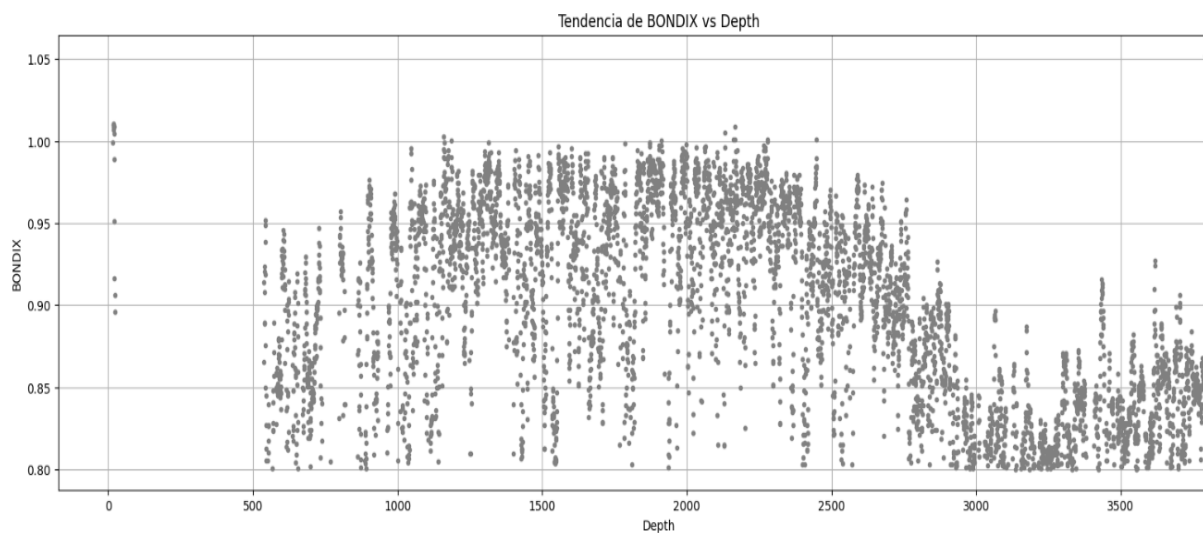
Con las variables se realiza un diagrama de tendencia donde el eje Y está compuesto por los datos de la columna BONDIX y el eje X está compuesto por los datos de la columna Depth (profundidad) como se aprecia en la figura 6. De igual forma se realiza un diagrama de tendencia tomando solo los valores de BONDIX superior a 0,8 y se presentan en la figura 7. Lo mismo se realiza para graficar la variable independiente AMP3FT (amplitud cbl) vs Depth (profundidad) figura 8.

**Figura 6.** *Diagrama de Bond Index CIRA4626*



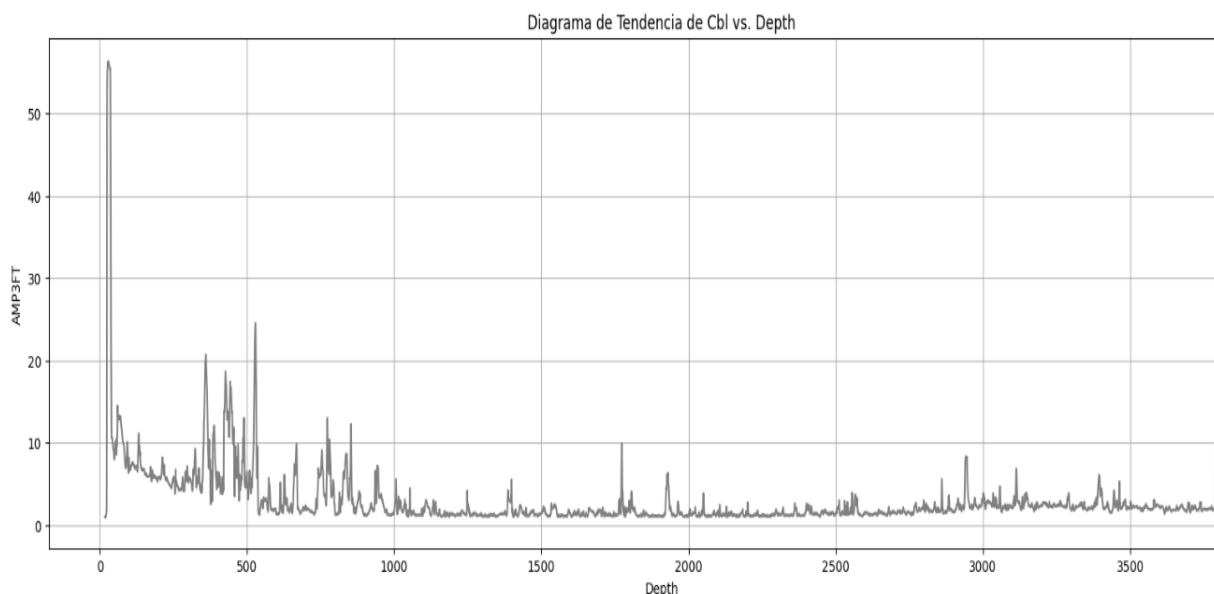
Nota. Fuente Google Colab.

**Figura 7.** *Diagrama de Bond Index superior a 0.8, CIRA4626*



Nota. Fuente Google Colab

**Figura 8.** *Diagrama de Amplitud CBL CIRA4626.*



Nota. Fuente Google Colab

En este proceso, se realiza la separación de los de datos ordenados en segmentos de 40 muestras que permite realizar análisis específicos en intervalos regulares de 2 pies, facilitando la identificación de patrones o características en bloques consistentes de datos, lo que mejora la precisión y claridad del análisis, optimizando la detección de anomalías, tendencias o comportamientos específicos dentro de los intervalos estudiados y beneficia el entrenamiento modelo de AI.

## **Fase 2: Selección del Algoritmo de Inteligencia Artificial**

En esta fase, se determina el algoritmo de inteligencia artificial más adecuado para el proyecto y los objetivos de la investigación. Se evaluaron dos opciones, como son Support Vector Machines (SVM) y Redes Neuronales Artificiales (ANN), y se seleccionó la que mejor se ajusta a las características de los datos y las necesidades del análisis.

Se decidió seleccionar el algoritmo de Máquinas de Soporte Vectorial (SVM) debido a su capacidad para clasificar datos en categorías, lo cual es fundamental en la tarea de análisis de registros de evaluación de cemento en pozos petroleros. Esta decisión se tomó tras evaluar las ventajas de SVM y ANN, considerando que SVM es especialmente eficaz para problemas de clasificación cuando se tiene un conjunto de datos limitado o cuando las categorías de

clasificación están claramente definidas, como es el caso de los registros donde se define buen cemento, regular cemento o mal cemento.

### Fase 3: Ejecución del Algoritmo y Entrenamiento del Modelo

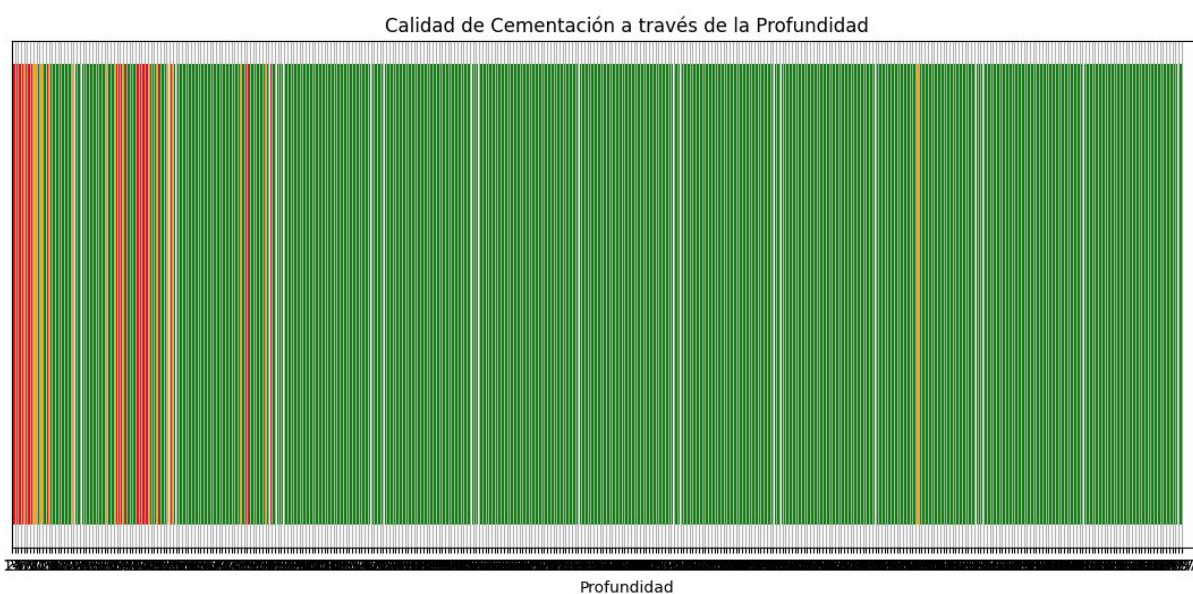
Se implementó el algoritmo seleccionado (SVM) utilizando el entorno de desarrollo de Google Colab. Se realiza la caracterización de los datos teniendo en cuenta la máxima amplitud de CBL, ajuste del 5% basado en la desviación estándar de la amplitud cbl, ajuste del 5% basado en la desviación estándar del bond index, combinación de resultados de la amplitud de cbl y bond index priorizando amplitud cbl.

**Tabla 3.** Caracterización de intervalos de profundidad según estado de cemento

Profundidad 17.0-36.5:	cementación mala
Profundidad 37.0-56.5:	cementación mala
Profundidad 57.0-76.5:	cementación mala
Profundidad 77.0-96.5:	cementación regular
Profundidad 97.0-116.5:	cementación regular
Profundidad 117.0-136.5:	cementación regular
Profundidad 137.0-156.5:	cementación buena
Profundidad 157.0-176.5:	cementación buena
Profundidad 177.0-196.5:	cementación buena
Profundidad 197.0-216.5:	cementación buena
Profundidad 217.0-236.5:	cementación buena

Nota. Fuente Google Colab.

**Figura 9.** Caracterización de color a intervalos según estado de cemento



Nota. Fuente Google Colab.

Se genera script para graficar la calidad de la cementación a lo largo de la profundidad de un pozo (figura 9). Cada segmento de profundidad caracterizado se colorea según su calidad: verde para buen cemento, naranja para regular cemento, y rojo para mala cementación. La gráfica ayuda a identificar rápidamente las zonas que requieren atención. Se guardan los valores de entrenamiento de las medidas estadísticas calculadas para la amplitud cbl y el bond index, y se cargan estos datos para entrenar el modelo SVM con kernel *lineal* `svm.SVC(kernel='linear')`, finalmente el algoritmo entrenado se guarda con el nombre *'modelo\_svm.pkl'*.

#### **Fase 4: Evaluación de la Confiabilidad de los Datos**

Este bloque de código evalúa el rendimiento del clasificador midiendo su precisión en el conjunto de prueba. Se utiliza el método `clf.score(X_test, y_test)` para calcular la proporción de predicciones correctas, y luego se imprime este valor formateado a dos decimales. La precisión debe oscilar entre 0 y 1, indica qué tan bien el modelo ha aprendido a generalizar sobre datos no vistos, y es crucial para determinar si el modelo es adecuado para su uso en producción o si necesita ajustes adicionales. Para este caso tras evaluar el modelo clasificador se obtiene una precisión del 0.97, lo quiere decir que el algoritmo de SMV entrenado tiene una precisión del 97%.

#### **Fase 5: Análisis de la Hipótesis**

Inicialmente, se planteó la Hipótesis Nula (Ho) sugiriendo que los algoritmos de inteligencia artificial no serían capaces de determinar el estado de la cementación en distintos intervalos de profundidad en los pozos del campo La Cira Infantas. Sin embargo, los resultados demostraron que estos algoritmos SVM sí pueden evaluar la calidad del cemento en esos intervalos. Esto nos lleva a rechazar la Hipótesis Nula y confirma la utilidad de la inteligencia artificial para este tipo de análisis.

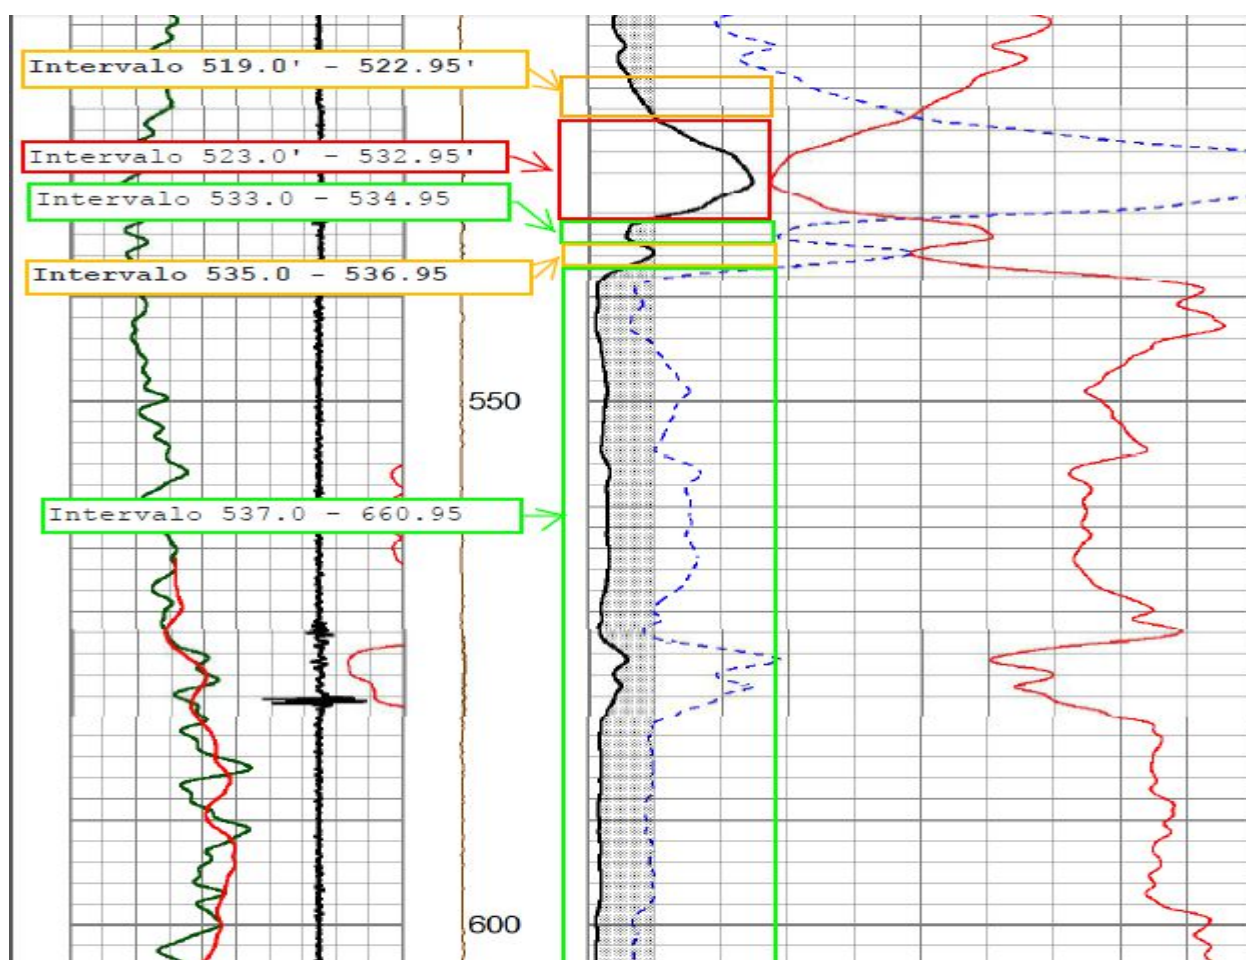
#### **Fase 6: Revisión y Modificación del Diseño Experimental**

En esta fase, se revisaron los resultados preliminares para determinar si es necesario ajustar el diseño experimental original. Los resultados son lo suficientemente precisos y cumplen con las expectativas de la investigación, por consiguiente, no se considera modificar el enfoque del estudio, o cambiar a un diseño preexperimental que incluya una preprueba y una posprueba. Este enfoque ha permitido afinar el análisis y obtener resultados claros y significativos.

### Fase 7: Presentación de los Resultados

Los resultados obtenidos destacan la calidad del cemento en distintos intervalos de profundidad del pozo evaluado, clasificada en tres categorías: buen cemento (verde), regular cemento (naranja) y mal cemento (rojo). Estos resultados fueron comparados con las gráficas en formato .pdf de las variables del registro de evaluación de cemento del mismo pozo, confirmando la precisión del algoritmo de inteligencia artificial. La concordancia observada entre los resultados proporcionados por el algoritmo y las imágenes del registro valida la eficacia del algoritmo en la interpretación de la calidad del cemento (ver Figura 10).

**Figura 10.** Grafica de variables vs resultados de algoritmo de IA



Nota. Sección del registro "CIRA4626\_RBT\_RL\_31JUL2024".

**Tabla 4.** Verificación de resultados con IA

#	Intervalo (ft)	Algoritmo IA	Verificación en el PDF
39	519.0 - 522.95	Cementación regular	Cementación regular
40	523.0 - 532.95	Cementación mala	Cementación mala
41	533.0 - 534.95	Cementación buena	Cementación buena
42	535.0 - 536.95	Cementación regular	Cementación regular
43	537.0 - 660.95	Cementación buena	Cementación buena

Nota. Elaboración propia

En la Tabla 4 se presentan los resultados de la verificación, donde se observa que, en los intervalos analizados, el algoritmo identifica correctamente la calidad del cemento en comparación con la verificación manual realizada a partir de las gráficas:

- En el intervalo de 519.0 a 522.95 pies, se clasifica como cementación regular (naranja), coincidiendo con la verificación.
- En el intervalo de 523.0 a 532.95 pies, se identifica como cementación mala (rojo), también coincidente.
- En el intervalo de 533.0 a 534.95 pies, se clasifica como cementación buena (verde), coincidiendo con la verificación.
- En el intervalo de 535.0 a 536.95 pies, se identifica como cementación regular (naranja), con verificación coincidente.
- En el intervalo de 537.0 a 660.95 pies, se clasifica como cementación buena (verde), nuevamente coincidente.

A continuación, se presentan los resultados completos del análisis del estado del cemento en el pozo "CIRA4626\_RBT\_RL\_31JUL2024\_MAIN\_20SPF" obtenidos mediante un algoritmo de inteligencia artificial. La Tabla 5 ofrece un desglose detallado de la calidad del cemento en diversos intervalos de profundidad, clasificando la cementación como buena, regular o mala. Estos resultados fueron verificados mediante la comparación con las gráficas del registro en formato PDF, confirmando la precisión del algoritmo y cumpliendo con las expectativas esperadas.

**Tabla 5. Resultado entregado por el algoritmo de IA del estado de cemento del pozo analizado "CIRA4626\_RBT\_RL\_31JUL2024\_MAIN\_20SPF"**

#	Intervalo (ft): Calidad del cemento	#	Intervalo (ft): Calidad del cemento
1	Intervalo 17.0 - 22.95: cementación buena	34	Intervalo 467.0 - 470.95: cementación regular
2	Intervalo 23.0 - 40.95: cementación mala	35	Intervalo 471.0 - 482.95: cementación buena
3	Intervalo 41.0 - 58.95: cementación regular	36	Intervalo 483.0 - 490.95: cementación regular
4	Intervalo 59.0 - 60.95: cementación mala	37	Intervalo 491.0 - 492.95: cementación mala
5	Intervalo 61.0 - 96.95: cementación regular	38	Intervalo 493.0 - 518.95: cementación buena
6	Intervalo 97.0 - 98.95: cementación buena	39	Intervalo 519.0 - 522.95: cementación regular
7	Intervalo 99.0 - 126.95: cementación regular	40	Intervalo 523.0 - 532.95: cementación mala
8	Intervalo 127.0 - 128.95: cementación buena	41	Intervalo 533.0 - 534.95: cementación buena
9	Intervalo 129.0 - 150.95: cementación regular	42	Intervalo 535.0 - 536.95: cementación regular
10	Intervalo 151.0 - 170.95: cementación buena	43	Intervalo 537.0 - 660.95: cementación buena
11	Intervalo 171.0 - 172.95: cementación regular	44	Intervalo 661.0 - 662.95: cementación regular
12	Intervalo 173.0 - 210.95: cementación buena	45	Intervalo 663.0 - 664.95: cementación buena
13	Intervalo 211.0 - 216.95: cementación regular	46	Intervalo 665.0 - 668.95: cementación regular
14	Intervalo 217.0 - 320.95: cementación buena	47	Intervalo 669.0 - 750.95: cementación buena
15	Intervalo 321.0 - 326.95: cementación regular	48	Intervalo 751.0 - 758.95: cementación regular
16	Intervalo 327.0 - 350.95: cementación buena	49	Intervalo 759.0 - 770.95: cementación buena
17	Intervalo 351.0 - 352.95: cementación regular	50	Intervalo 771.0 - 774.95: cementación mala
18	Intervalo 353.0 - 366.95: cementación mala	51	Intervalo 775.0 - 776.95: cementación regular
19	Intervalo 367.0 - 374.95: cementación regular	52	Intervalo 777.0 - 778.95: cementación buena
20	Intervalo 375.0 - 382.95: cementación buena	53	Intervalo 779.0 - 784.95: cementación regular
21	Intervalo 383.0 - 384.95: cementación mala	54	Intervalo 785.0 - 832.95: cementación buena
22	Intervalo 385.0 - 392.95: cementación regular	55	Intervalo 833.0 - 840.95: cementación regular
23	Intervalo 393.0 - 420.95: cementación buena	56	Intervalo 841.0 - 852.95: cementación buena
24	Intervalo 421.0 - 422.95: cementación mala	57	Intervalo 853.0 - 854.95: cementación mala
25	Intervalo 423.0 - 424.95: cementación regular	58	Intervalo 855.0 - 942.95: cementación buena
26	Intervalo 425.0 - 430.95: cementación mala	59	Intervalo 943.0 - 944.95: cementación regular
27	Intervalo 431.0 - 440.95: cementación regular	60	Intervalo 945.0 - 1772.95: cementación buena
28	Intervalo 441.0 - 448.95: cementación mala	61	Intervalo 1773.0 - 1774.95: cementación mala
29	Intervalo 449.0 - 454.95: cementación regular	62	Intervalo 1775.0 - 2938.95: cementación buena
30	Intervalo 455.0 - 456.95: cementación mala	63	Intervalo 2939.0 - 2946.95: cementación regular
31	Intervalo 457.0 - 458.95: cementación buena	64	Intervalo 2947.0 - 3788.95: cementación buena
32	Intervalo 459.0 - 464.95: cementación regular	65	Intervalo 3789.0 - 3790.95: cementación mala
33	Intervalo 465.0 - 466.95: cementación buena	66	Intervalo 3791.0 - 3802.0: cementación buena

Nota. Elaboración propia

## Conclusiones

Se concluye que el modelo clasificador entrenado utilizando el algoritmo SVM demuestra un rendimiento eficaz, alcanzando una precisión del 97% en el conjunto de prueba. Este alto nivel de precisión indica que el modelo logra trabajar con un nivel de confianza alto sobre datos no vistos, lo cual es un indicador positivo para poner en práctica este desarrollo.

La integración de la inteligencia artificial (IA) en el análisis de registros de evaluación de cemento en pozos petroleros, específicamente en el campo La Cira Infantas, demuestra que las herramientas artificiales aplicadas, como Máquinas de Vectores de Soporte (SVM) y Redes Neuronales Artificiales (ANN), son altamente efectivas para mejorar la precisión y rapidez en la interpretación de estos registros.

Las herramientas de (IA) permiten identificar patrones complejos y correlaciones que pueden pasar desapercibidos en análisis manuales, lo que responde directamente a la necesidad planteada de optimizar la evaluación de los registros de cementación en pozos.

Los resultados obtenidos muestran que el uso de IA puede reducir significativamente la variabilidad en las interpretaciones de los registros de cementación, minimizando la subjetividad, mejorando la interpretación y análisis. Se observó que el modelo de IA, entrenados con datos actuales, pueden predecir con alta precisión la calidad de la cementación, identificando zonas de posible falla que requieren intervención.

Este estudio confirma que la aplicación de IA en la industria petrolera puede transformar la manera en que se realizan los análisis de cementación, ofreciendo una herramienta novedosa para garantizar la integridad de los pozos y reducir costos operativos. Además, los hallazgos expanden el conocimiento existente al demostrar que la IA no solo es viable, sino necesaria para abordar los registros de evaluación de cemento, estableciendo un nuevo modelo en la industria para el análisis de la cementación.

### **Recomendaciones**

Se recomienda la implementación de Redes Neuronales Artificiales (ANN) como una opción adecuada para el análisis de registros de evaluación de cemento en pozos petroleros. Donde las relaciones entre las variables (CBL, Bondindex, etc.) no son lineales. Ya que las ANN tienen la capacidad de modelar relaciones no lineales complejas en los datos, lo que será fundamental para lograr predicciones más precisas en futuros desarrollos.

Se observó que el modelo de IA, entrenado con los datos actuales de los pozos, pueden predecir con alta precisión la calidad de la cementación, identificando zonas de posible falla que requieren intervención. Sin embargo, es importante entrenar el algoritmo con datos históricos de pozos.

Se sugiere evaluar el uso de métodos estadísticos alternativos al cálculo de la media y la desviación estándar para analizar los cambios abruptos en la amplitud del CBL, lo que podría ofrecer una mejor comprensión de las variaciones críticas en la calidad del cemento.

## Referencias

- ACIPET. (30 de ABRIL de 2020). Interpretación De Registros De Cementación.  
<https://www.youtube.com/watch?v=y4X2KdgAAg8>.
- Bernal, C. A. (2016). Redacción de un anteproyecto. En *Metodología de la investigación: Administración, economía, humanidades y ciencias sociales* (págs. 275-290). Pearson Educación.
- Dinesh , A., Kamal, B., Akash, M., & Surthik, K. (2024). Implementation of artificial intelligence to the prediction of the mechanical properties of concrete: A review. *ELSEVIER*, 2-5.
- Hernández, R., & Mendoza, C. (s.f.). Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta. En *Concepción o elección del diseño de investigación en la ruta cuantitativa: el mapa específico* (págs. 150-172). McGraw-Hill.
- KAPPA. (04 de 02 de 2024). *Petroleum Exploration & Production - Software Training & Consulting*. <https://www.kappaeng.com/software/emeraude/overview>
- Obafemi, s., Oyedele, K., Omeru, T., & Bankole, S. (2020). Characterization of deep water turbidite channels and submarine fan lobes using artificial intelligence; Case study of Frem Field deep offshore Niger Lobes. *ELSEVIER*.
- Ogunkunle, T., Okoro, E., & Oluwatosin, J. (2021). Artificial intelligence model for predicting geomechanical characteristics using easy-to-acquire offset logs without deploying logging tools. *ScienceDirect*, 3-8.
- Probe Holdings. (2012). *2.75" Radii Cement Bond Tool*. Copyright Probe Holdings, Inc.
- Schlumberger. (2024). <https://www.slb.com/products-and-services/innovating-in-oil-and-gas/drilling/drilling-fluids-and-well-cementing/well-cementing/cement-evaluation/cement-bond-logging-tools>
- Scientific Data Systems, Inc. (03 de FEBRERO de 2024). *Software de adquisición de datos Warrior*. <http://www.scientificdata.com/products/WarriorSoftware.html>

Topes Rojas., P. A., Bisbé, E. M., & Valcarce Ortega., R. M. (Enero de 2017). *Monografias.com* S.A. <https://www.monografias.com/docs112/registros-geofisicos-control-estado-pozos-petroleros/registros-geofisicos-control-estado-pozos-petroleros2>

World Energy Trade. (09 de agosto de 2023). *Cómo la IA está transformando las operaciones de petróleo y gas*. <https://www.worldenergytrade.com/oil-gas/investigacion/la-ia-petroleo-y-gas-19411>.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson Education.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

Anexos

Anexo 1. Tabla amplitud máxima de CBL en tubería libre según diámetro de casing.



CEMENT BOND LOG  
CASING DATA  
(Including Tool Delay)

Pipe		1-11/16" CBL		2-3/4" CBL		Pipe		2-3/4" CBL	
O.D.	Weight	AMP	3 FT	5FT	3 FT	5FT	O.D.	Weight	AMP
2.375	4.00	119.5	230	340	273	382	9.625	29.30	51.3
4.70	1.995		230	340	272	380	32.30	9.001	
5.95	1.867		227	337	271	379	36.00	8.921	
2.875	6.50	106.5	237	347	280	390	40.00	8.835	
7.90	2.323		235	345	283	392	43.50	8.755	
8.70	2.259		234	344	282	390	47.00	8.681	
9.50	2.195		233	343	280	388	53.50	8.535	
10.70	2.091		231	341	281	401	58.40	8.435	
11.00	2.065		231	341	289	399	61.10	8.375	
3.500	9.30	94.5	246	356	303	413	71.80	8.125	
10.20	2.922		245	355	302	412	10.750	32.75	48.0
12.80	2.764		242	352	300	411	40.50	10.050	
12.95	2.750		242	352	299	409	45.50	9.950	
15.80	2.548		239	349	298	408	51.00	9.850	
16.70	2.480		237	347	296	406	55.00	9.760	
4.000	9.50	87.2	255	365	295	405	60.70	9.650	
11.00	3.476		254	364	293	403	65.70	9.550	
4.500	9.50	81.2	264	374	313	423	11.750	38.00	45.5
10.50	4.052		263	373	311	421	42.00	11.084	
11.60	4.000		262	372	306	416	47.00	11.000	
13.50	3.920		261	371	309	419	54.00	10.880	
15.10	3.825		259	369	307	417	60.00	10.772	
5.000	11.50	76.2	271	381	305	415	13.380	48.00	42.0
13.00	4.494		270	380	302	412	54.50	12.615	
15.00	4.408		269	379	341	451	61.00	12.515	
16.00	4.276		267	377	339	449	68.00	12.415	
20.30	4.184		265	375	338	448	72.00	12.347	
23.20	4.044		263	373	336	446	85.00	12.276	
24.20	4.000		262	372	334	444	16.000	55.00	37.7
5.500	13.00	71.9	279	389	333	443	75.00	15.124	
14.00	5.012		279	389	329	439	84.00	15.010	
15.50	4.950		278	388	306	414			
17.00	4.852		277	387					
20.00	4.778		275	385					
23.00	4.670		273	383					
25.00	4.548		271	381					

■ Questionable Usage

Actual transit times recorded under field conditions can vary by as much as 5%.  
Times are based upon a borehole fluid of water with 500 psi applied and will vary with borehole fluid velocity, pressure, temperature

Fuente. (Probe Holdings, 2012)

**Anexo 2. Representación de archivo .LAS con data del pozo evaluado.**

CIRA4626\_RBT\_RL\_31JUL2024\_MAIN\_20SPF: Bloc de notas

Archivo Edición Formato Ver Ayuda

~Parameter Information  
 ~Other Information  
 1. OBJETIVE: CEMENT EVALUATION FOR 7.0" CASING.  
 2. LOG ON DEPTH WITH COMPENSATED NEUTRON-DENSITY POROSITY PROPAGATION RESISTIVITY GAMMA RAY LOG BY IONOS ON 29-JUL-2024.  
 3. ALL PASSES WITNESSED BY CLIENT REPRESENTATIVE.  
 4. MISSING HEADER DATA NOT AVAILABLE AT WELLSITE.  
 5. CASING OD AND WEIGHT AVAILABLE BY CLIENT REPRESENTATIVE.  
 6. PASS LOGGED WITHOUT ADDITIONAL PRESSURE.  
 7. EXPECTED CBL AMPLITUDE FOR 7.0" CASING IN FREE PIPE IS 62.2 mV.  
 8. IN THE VAD, FREE PIPE IS SHOWN IN BLUE COLOR AND GOOD CEMENT IN BLACK COLOR.  
 9. TAIL CEMENT: 15' - 3840' DENSITY: 14.6 PPG

~A Depth	LTEN	GR	TT3FT	CCL	AMP3FT	BONDIX
3802.0000	883.8139	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.9500	883.8139	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.9000	883.8139	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.8500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.8000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.7500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.7000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.6500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.6000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.5500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.5000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.4500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.4000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.3500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.3000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.2500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.2000	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.1500	867.9665	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.1000	866.9760	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.0500	866.9760	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3801.0000	866.9760	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.9500	866.9760	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.9000	866.9760	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.8500	984.8412	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.8000	984.8412	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.7500	984.8412	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.7000	984.8412	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.6500	984.8412	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.6000	1061.1068	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.5500	1061.1068	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.5000	1061.1068	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.4500	1061.1068	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.4000	1061.1068	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500
3800.3500	1086.8589	-999.2500	-999.2500	-999.2500	-999.2500	-999.2500

Fuente. Autor

### Anexo 3. Programación en Python mediante Google Colab.

Programación en Python, sistema de inteligencia artificial en el análisis de registros de evaluación de cemento en pozos petroleros del campo La Cira-Infantas

```
import pandas as pd
import pickle
import matplotlib.pyplot as plt
from sklearn import svm
from sklearn.model_selection import train_test_split

#file_name = 'CIRA6135_RBT-RL_03DIC2023_MAIN_2SPF.las' #nombre del archivo
AMPFREE = 71.9 #valor de amplitud en tuvo libre"
from google.colab import files
uploaded = files.upload()
file_name = next(iter(uploaded))

#Lectura del .las para analisis
skiprows = 0
with open(file_name, 'r') as f:
    for line in f:
        if '~A' in line:
            break
        skiprows += 1

df = pd.read_csv(file_name, skiprows=skiprows, delim_whitespace=True, header=None)

# prompt: Promueve los encabezados 1 fila y desplaza el titulo de los encabezados una
casilla a la izquierda

df.columns = df.iloc[0].shift(-1)
df = df.iloc[1:]

# prompt: Elimina la columna que no tiene nombre en el encabezado

df = df.loc[:, ~df.columns.isna()]

for col in df.columns:
    if df[col].dtype == 'object':
        try:
            df[col] = df[col].astype(float)
        except ValueError:
            pass

#Ordenar los datos de menor a mayor usando como referencia la columna Depth

df_sorted = df.sort_values('Depth')

#Convertir a 0 todos los valores negativos de las variables a trabajar BONDIX y AMP3FT
```

```
df_sorted['BONDIX'] = df_sorted['BONDIX'].apply(lambda x: 0 if x < 0 else x)
df_sorted['AMP3FT'] = df_sorted['AMP3FT'].apply(lambda x: 0 if x < 0 else x)
```

```
#Separaci3n de los datos en vectores de 40 muestras para caracterizaci3n cada 20 pies
segment_df = [df_sorted.iloc[i:i+40][['BONDIX', 'AMP3FT']] for i in range(0, len(df_sorted),
40)]
```

```
#funcion que realiza el calculo de las medidas estadisticas para caracterizar
def statistical_measures(segment_df):
```

```
    coef_bondix = []
    coef_amp3ft = []
    for div in segment_df:
        #medidas estadisticas de bondix [media, mediana, desviaci3n estandar, variaci3n
estandar]
        desc_bondix = div['BONDIX'].describe()[['mean', '50%', 'std']]
        desc_bondix['var'] = div['BONDIX'].var()
        coef_bondix.append([desc_bondix['mean'], desc_bondix['50%'], desc_bondix['std'],
desc_bondix['var']])
        #medidas estadisticas de la amplitud [media, mediana, desviaci3n estandar, variaci3n
estandar]
        desc_amp3ft = div['AMP3FT'].describe()[['mean', '50%', 'std']]
        desc_amp3ft['var'] = div['AMP3FT'].var()
        coef_amp3ft.append([desc_amp3ft['mean'], desc_amp3ft['50%'], desc_amp3ft['std'],
desc_amp3ft['var']])

    coef = [coef_amp3ft, coef_bondix]
    return coef
```

```
coef=statistical_measures(segment_df=segment_df)
```

```
dataclass = {} #diccionario donde se van a guardar las medidas estadisticas es de la forma
{depth_range:[measures_AMP3FT, measures_BONDIX]}
```

```
for i, segment in enumerate(segment_df): #este bucle se usa para generar las claves que
guardan los rangos de profundidad
```

```
    profundidad_inicio = df_sorted.iloc[i*40]['Depth']
    if (i+1)*40-1 < len(df_sorted):
        profundidad_fin = df_sorted.iloc[(i+1)*40-1]['Depth']
    else:#esto es para la ultima parte cuando no alcanzan los datos para completar las 40
muestras
```

```
    profundidad_fin = df_sorted.iloc[-1]['Depth']
    rango_profundidad = f"{profundidad_inicio}-{profundidad_fin}"
    dataclass[rango_profundidad] = [
        [round(val,2) for val in coef[0][i]],
        [round(val,2) for val in coef[1][i]]]
```

```
# Cargar el modelo entrenado desde un archivo con pickle
```

```
with open('modelo_svm.pkl', 'rb') as file:
```

```
    clf_cargado = pickle.load(file)
```

```
datapredict = []
```

```
for key in dataclass:
```

```

line=str(dataclass[key])
# Eliminar corchetes y espacios innecesarios
line = line.replace('[', '').replace(']', '').strip()
# Convertir la línea en una lista de floats
float_list = [float(num) for num in line.split(',')]
# Agregar la lista de floats a xtraining
datapredict.append(float_list)

# Realizar predicciones
predictions = clf_cargado.predict(datapredict)

# Crear el diccionario characterization
characterization = {}
for i, depth_range in enumerate(dataclass.keys()):
    # Asignar la predicción correspondiente a cada rango de profundidad
    characterization[depth_range] = predictions[i]

# Definir los colores para cada categoría
color_map = {
    'cementación buena': 'green',
    'cementación regular': 'orange',
    'cementación mala': 'red'
}

# Preparar los datos para la gráfica
depth_ranges = list(characterization.keys())
depth_starts = [float(dr.split('-')[0]) for dr in depth_ranges]
depth_ends = [float(dr.split('-')[1]) for dr in depth_ranges]
colors = [color_map[characterization[dr]] for dr in depth_ranges]

# Crear la gráfica
plt.figure(figsize=(14, 6))

for i in range(len(depth_starts)):
    plt.barh(1, width=depth_ends[i]-depth_starts[i], left=depth_starts[i], color=colors[i])

# Configuraciones de la gráfica
plt.yticks([])
plt.xticks(range(int(min(depth_starts)), int(max(depth_ends)) + 1, 10))
plt.xlabel('Profundidad')
plt.title('Calidad de Cementación a través de la Profundidad')
plt.grid(True)

# Mostrar la gráfica
plt.show()

# Agrupar intervalos continuos con el mismo color
grouped_intervals = []
current_interval = None
for i in range(len(depth_starts)):
    if current_interval is None:

```

```

    current_interval = {'start': depth_starts[i], 'end': depth_ends[i], 'color': colors[i]}
elif current_interval['color'] == colors[i]:
    current_interval['end'] = depth_ends[i]
else:
    grouped_intervals.append(current_interval)
    current_interval = {'start': depth_starts[i], 'end': depth_ends[i], 'color': colors[i]}

if current_interval is not None:
    grouped_intervals.append(current_interval)

# Imprimir los intervalos agrupados con su descripción
for interval in grouped_intervals:
    for key, value in color_map.items():
        if interval['color'] == value:
            description = key
            break
    print(f"Intervalo {interval['start']} - {interval['end']}: {description}")

```