

UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA PETROLERA



PROYECTO DE GRADO
“DETERMINACIÓN DE TIEMPOS NO PRODUCTIVOS EN LA
PERFORACIÓN DE POZOS EXPLORATORIOS EN EL SUB
ANDINO DE BOLIVIA, APLICANDO ALGORITMOS DE
APRENDIZAJE AUTOMÁTICO BASADO EN DATOS ESTADÍSTICOS”

Proyecto de Grado presentado para optar por el título de Licenciatura en
Ingeniería en Petróleo Gas y Procesos

POSTULANTE: NERCY KAREN LIMACHI QUISPE
TUTOR: ING. JUAN FERNANDO CUEVAS BANDA

La Paz - Bolivia

2024



**UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERIA**



LA FACULTAD DE INGENIERIA DE LA UNIVERSIDAD MAYOR DE SAN ANDRÉS AUTORIZA EL USO DE LA INFORMACIÓN CONTENIDA EN ESTE DOCUMENTO SI LOS PROPÓSITOS SON ESTRICTAMENTE ACADÉMICOS.

LICENCIA DE USO

El usuario está autorizado a:

- a) Visualizar el documento mediante el uso de un ordenador o dispositivo móvil.
- b) Copiar, almacenar o imprimir si ha de ser de uso exclusivamente personal y privado.
- c) Copiar textualmente parte(s) de su contenido mencionando la fuente y/o haciendo la cita o referencia correspondiente en apego a las normas de redacción e investigación.

El usuario no puede publicar, distribuir o realizar emisión o exhibición alguna de este material, sin la autorización correspondiente.

TODOS LOS DERECHOS RESERVADOS. EL USO NO AUTORIZADO DE LOS CONTENIDOS PUBLICADOS EN ESTE SITIO DERIVARA EN EL INICIO DE ACCIONES LEGALES CONTEMPLADAS EN LA LEY DE DERECHOS DE AUTOR.

AGRADECIMIENTOS

En primer lugar, deseo expresar mi más profundo agradecimiento a mi padre, Jhonny Limachi Villazante, por guiarme con valores y enseñanzas. Su sabiduría y generosidad han sido fundamentales en mi formación. Gracias por ser mi fuente de inspiración.

A mi madre, Nelzy Quispe Cuajera, y a mi hermana, Anahy Estefany Limachi Quispe, por su amor incondicional, comprensión y sacrificios. Su confianza en mí y sus palabras de aliento han sido mi principal fuente de energía durante estos años.

Quiero expresar mi profundo respeto al Ing. Juan Fernando Cuevas Banda, cuyo conocimiento, paciencia y orientación fueron fundamentales para la realización de este proyecto. Estoy sinceramente agradecido por su constante apoyo, presencia y sentido de responsabilidad hacia mí.

Finalmente, deseo mostrar mi profunda gratitud a las personas que han sido verdaderas musas inspiradoras para este proyecto. Su influencia y ejemplo han iluminado cada día de mi camino hacia este logro

DEDICATORIA

Dedico este proyecto a la valiente travesía del ser humano en la búsqueda incansable de sus sueños, aún en los momentos en que el horizonte parece incierto y los desafíos son mayores. Que este trabajo honre esa perseverancia e inspire a seguir adelante con fe y determinación.

INDICE

SIMBOLOGÍA.....	VIII
RESUMEN EJECUTIVO	1
1 CAPÍTULO 1: GENERALIDADES	2
1.1 INTRODUCCIÓN.....	2
1.2 ANTECEDENTES	3
1.2.1 Antecedentes del área de aplicación	3
1.2.2 Antecedentes la propuesta	8
1.2.3 Antecedentes de la investigación	9
1.3 PLANTEAMIENTO DEL PROBLEMA.....	10
1.3.1 Identificación del problema	10
1.3.2 Formulación del problema	11
1.4 OBJETIVOS	11
1.4.1 Objetivo general.....	11
1.4.2 Objetivos específicos.....	11
1.4.3 Desarrollo de las actividades.....	12
1.5 1.7 JUSTIFICACIÓN	13
1.5.1 Justificación técnica.....	13
1.5.2 Justificación económica.....	14
1.5.3 Justificación ambiental.....	14
1.5.4 Justificación teórica	14
1.6 ALCANCES	15
1.6.1 Alcance temático	15
1.6.2 Alcance geográfico	15
1.6.3 Alcance temporal	16

2	CAPÍTULO 2: TIEMPOS NO PRODUCTIVOS EN LA PERFORACIÓN DE POZOS PETROLEROS	17
2.1	TIEMPOS DE LA PERFORACIÓN	17
2.2	CLASIFICACIÓN Y TIPOS DE PERFORACIÓN.....	18
2.2.1	Perforación rotatoria	18
2.3	TIPOS DE EQUIPOS DE PERFORACION	19
2.2.2	Equipos de perforación terrestres.....	19
2.2.3	Equipos terrestres auto transportables	19
2.2.4	Equipos de Perforación Lacustres	20
2.2.5	Equipos de perforación Marinos (Plataforma autoelevable Jack Up)	20
2.3	BARRENAS.....	20
2.3.1	Principios de corte (Principios de ataque).....	21
2.3.2	Características de las barrenas	21
2.4	DAÑOS A LA FORMACIÓN POR LA PERFORACIÓN.....	24
2.5	PROBLEMAS ASOCIADOS A LA PÉRDIDA DE TIEMPO EN LA PERFORACIÓN	24
2.6	CLASIFICACIÓN DE TIEMPOS DE PERFORACIÓN	26
2.6.1	Tiempo programado.....	26
2.6.2	Tiempo productivo	26
2.6.3	Tiempo no productivo	27
2.6.4	Tiempo invisible	27
2.7	EL PROBLEMA PRINCIPAL DE LOS TIEMPOS NO PRODUCTIVOS O NPTS	27
3	CAPÍTULO 3: ALGORITMOS DE APRENDIZAJE AUTOMÁTICO COMO METODOLOGÍA PARA PREDICCIÓN DE NPT'S.....	31
3.1	REDES NEURONALES DE INTELIGENCIA ARTIFICIAL.....	31
3.1.1	Big Data.....	31

3.1.2	Minería de datos	31
3.2	DEFINICION DE MACHINE LEARNING	32
3.2.1	Definición.....	32
3.2.2	Conceptos previos del Machine Learning.....	33
3.3	FUNDAMENTOS DEL MACHINE LEARNING	34
3.3.1	El aprendizaje.....	35
3.3.2	El error y los problemas de ajuste	36
3.3.3	Etapas de un proyecto de Machine Learning.....	37
3.4	ALGORITMOS DE MACHINE LEARNING.....	40
3.4.1	Aprendizaje supervisado.....	40
3.4.2	Aprendizaje No supervisado	40
3.4.3	Aprendizaje Forzado.....	41
3.5	MÉTODOS DEL MACHINE LEARNING EN PERFORACIÓN.....	41
3.5.1	Método de Machine Learning vectorial para predecir la NPT en la perforación	41
3.5.2	ANFIS (Sistema de Inferencia Neuro-Difusa Adaptativa)	43
3.5.3	PSO-ANFIS (Optimización de Enjambre de Partículas-Sistema de Inferencia Neuro-Difusa Adaptativa).....	44
3.5.4	LSSVM-GA (Máquina de Vector de Soporte de Mínimo Cuadrado)	45
3.5.5	RBF (Función de Base Radial)	45
4	CAPÍTULO 4: DESCRIPCIÓN DEL BLOQUE SUB ANDINO	46
4.1	CORRELACIÓN HIDROCARBURO – ROCA MADRE.....	46
4.2	RESERVORIOS Y TRAMPAS	49
4.2.1	Porosidad del reservorio.....	49
4.2.2	Subandino Sur.....	50
5	CAPÍTULO 5: APLICACIÓN PRÁCTICA	54

5.1	DATOS DE PRESIÓN PERFORACIÓN PLANIFICADOS PARA EL BLOQUE SUB ANDINO.....	54
5.2	MODELOS PREDICTIVOS DE MACHINE LEARNING para el control de tiempos no productivos en la perforación	57
5.2.1	Desarrollo del modelo en Machine learning.....	57
5.2.2	Obtención de datos de tiempos de producción con Machine learning ...	64
5.2.3	Obtención de las funciones de los modelos.....	66
5.3	VALIDACIÓN DEL MODELO	72
5.3.1	Desarrollo analítico del modelo.....	72
5.4	PLAN DE RIESGOS.....	79
6	CAPÍTULO 6: COSTOS DEL PROYECTO.....	83
6.1	INTRODUCCIÓN AL ANÁLISIS.....	83
6.2	ANÁLISIS DE COSTOS	83
6.2.1	Costos fijos	83
6.2.2	Costos Variables de predicción de tiempos no productivos	84
6.3	COMPARACIÓN DE PÉRDIDAS DE TIEMPOS NO PRODUCTIVOS	85
6.4	ANÁLISIS DE COSTO Y BENEFICIO	88
7	CAPÍTULO 7: CONCLUSIONES Y RECOMENDACIÓN.....	90
7.1	CONCLUSIONES.....	90
7.2	RECOMENDACIONES	91
	BIBLIOGRAFÍA	92
	GLOSARIO	94
8	ANEXOS	95
	ANEXOS A: REQUISITOS DE CONTRATO POR PARTE DE YPFB CHACO	95
	ANEXOS B: DATOS DE RESPALDO DE SIMULACIÓN	102
	ANEXOS C: CONFIGURACIÓN DE MACHINE LEARNING EN MATLAB	105
	ANEXOS D: RELACIÓN DE PREDICCIÓN DE DATOS.....	108

ANEXOS E: PROFUNDIDAD ESTIMADA CON EL MODELO 111

INDICE DE FIGURAS

Figura 1. 1: Estratigrafía del bloque Sub Andino	7
Figura 1. 2: Presentación de espesores de la estratigrafía del Subandino Sur	8
Figura 1. 3: Ubicación del Área Sub Andino Sur	16
Figura 2. 1: Componentes principales del costo del pozo	25
Figura 3. 1: Método de aprendizaje del machine learning	35
Figura 3. 3: Etapas genéricas para llevar a cabo un proyecto de.....	38
Figura 4. 1: Correlación de petróleo	47
Figura 4. 2: Evaluaciones de la madurez térmica de las muestras de gas.....	48
Figura 4. 3: Mapa estructural del subandino	50
Figura 4. 4: Mapa Isópaco de la formación los Monos	51
Figura 4. 5: Mapa isópaco del reservorio Huamampampa	52
Figura 4. 6: Características del subandino	52
Figura 5. 1: Perfil del pozo HYC X1	55
Figura 5. 2: Perfil del pozo HCW X2.....	56
Figura 5. 3: Diagrama de flujo del algoritmo PSO	58
Figura 5. 4: Diagrama de flujo se la simulación en Matlab	59
Figura 5. 4: Presentación de bienvenida a Matlab	60
Figura 5. 6: Función del primer modelo	61
Figura 5. 7: Función del segundo modelo	61
<i>Figura 5. 8: Función del tercer modelo</i>	62
Figura 5. 9: Función del cuarto modelo	63
<i>Figura 5. 10: Función del quinto modelo</i>	64
Figura 5. 11: Tiempo de perforación para distintos modelos.....	65
Figura 5. 12: Relación de modelos de Machine learning.....	66
Figura 5. 13: Variación de porcentaje de perforación	64
Figura 5. 14: Predicción de ROP óptimo	73
Figura 5. 15: Relación de modelo de Machine learning con regresión polinómica ...	74
Figura 5. 16: Validación del modelo	75
Figura 5. 17: Profundidad estimada	76

INDICE DE TABLAS

Tabla 1. 1: Descripción estratigráfica del Bloque Sub Andino Sur	4
Tabla 1. 2: Problemas identificados durante el desarrollo de pozos en el Sub Andino Sur.....	10
Tabla 1. 3: Desarrollo de las actividades.....	12
Tabla 5. 1: Datos del perfil del pozo HYC X1	54
Tabla 5. 2: Datos del perfil del pozo HCW X2	54
Tabla 5. 3: Datos de tiempos de perforación para diferentes modelos de interacción.....	65
Tabla 5. 4: Datos de varios modelos de predicción de presión	66
Tabla 5. 5: Variación de datos de perforación	72
Tabla 5. 6: Variación reducida de datos de perforación	73
Tabla 5. 7: Variación de datos de perforación	75
Tabla 5. 8: Datos de validación de presión de fondo total	77
Tabla 5. 9: Tiempos no productivos y tiempos óptimos.....	78
Tabla 5. 10: Plan de Riesgos para evitar TNPS	79
Tabla 6. 1: Análisis de costos fijos	83
Tabla 6. 2: Costos variables	84
Tabla 6. 3: Costos variables sin pérdida por NPT	85
Tabla 6. 4: Comparación de costos	85
Tabla 6. 5: Interpretación de Costo y beneficios	88

SIMBOLOGÍA

ω	Factor de peso
a_i	Factor de arreglo
b	Término de sesgo
C	Constante de regularización
e_k	Función de error de entrenamiento
c_1 y c_2	Constantes positivas
r_1 y r_2	Funciones aleatorias en el rango [0,1]
$x_i = (x_{i1}, x_{i2}, \dots, x_{id})$	i-ésima partícula
$p_i = (p_{i1}, p_{i2}, \dots, p_{id})$	Mejor posición anterior de la i-ésima partícula (la posición con el valor de fitness más alto)
g	Representa la gravedad a la que se somete un fluido.
$v = (v_{i1}, v_{i2}, \dots, v_{id})$	Índice de la mejor partícula de la población
$\sum_{i=1}^N a_i K(x, x_i) + b$	Formulación de una recta iterada por sumatoria
$f(x)$	Función de una variable
δ	Variación de dato
γ	Valor mínimo sigma
I_n	Factor de corrección
MSE	Mean Square Error (Error cuadrado medio)
ρ_{est}	Valor estimado
ρ_{exp}	Valor obtenido o experimental
n_s	Número de iteraciones

RESUMEN EJECUTIVO

En este proyecto de grado se realiza un análisis predictivo de los tiempos no productivos para el diseño de futuros pozos exploratorios en el sub andino sur. La inteligencia artificial permite tratar de predecir, pronosticar o anunciar el comportamiento de la perforación de pozos a partir del diseño de otros realizados en la zona o área de interés; es lo que se realizará en este proyecto, evitar perder el tiempo en la perforación a través del uso de datos de perforación de pozos en el pasado. Se ha podido utilizar la tecnología de inteligencia artificial de red neuronal para predecir la probabilidad de evitar los tiempos no productivos en la planificación de pozos en el sub Andino Sur.

Se determinó eficazmente los parámetros de perforación mediante la simulación del modelo propuesto con datos de pozos con y sin NPT para la planificación de futuros pozos aplicando el software Matlab. Se pudo desarrollar un plan de riesgos a partir de la simulación para evitar futuros NPT's en la planificación de nuevos pozos en el bloque Sub Andino.

El análisis de factibilidad técnico – económica indica que el proyecto se puede realizar fácilmente con bajo presupuesto debido a que el dinero solo se destina en la capacitación para el manejo de Machine learning en un sector de profesionales dentro de la empresa.

Se logró estimar eficazmente los tiempos no productivos en la perforación de pozos exploratorios en el Sub Andino de Bolivia, aplicando el algoritmo de Aprendizaje automático con datos estadísticos.

CAPÍTULO 1: GENERALIDADES

1.1 INTRODUCCIÓN

La metodología de redes neuronales o inteligencia artificial está creciendo cada año y genera un crecimiento en la tecnología y en la optimización de soluciones dentro de la ingeniería (Haefner & Wincent, 2021). Esta inteligencia artificial se basa en modelos de aprendizaje automático, conocido como Machine learning y aprendizaje profundo o Deep learning. Actualmente, la industria petrolera necesita de herramientas que apoyen a proporcionar soluciones ágiles, como el que se analizará en el Proyecto de Grado, sobre todo en la parte de upstream.

Muchos ingenieros dedicados al área de perforación y a la investigación consideran que se debe minimizar el tiempo improductivo (Non-Productive Time, NPT) durante el proceso de perforación y cementación de pozos utilizando como herramienta principal a la inteligencia artificial. Es necesario entonces determinar la probabilidad de que un intervalo de tiempo contenga un comportamiento anómalo en un pozo determinado que puede concluir en un incidente o accidente (Ayala, 2017).

El modelo de Machine learning se basa en registros de pozo, datos de cementación, presiones de poro y otros datos necesarios que ayuden en perfilar el comportamiento de una determinada construcción, conociendo estos datos la información obtenida de pozos perforados en la zona y de las estructuras se pretende reducir los NPT en un determinado porcentaje. El algoritmo de Machine learning que se llegará a utilizar es el de Enjambre de partículas (PSO). Donde se considerará la presión diferencial, la profundidad del pozo en construcción y las características del lodo de perforación

Las causas de los tiempos no productivos se explicarán en este proyecto de grado, a partir de la determinación de la cantidad de fallas que se presentan durante la perforación en un campo determinado para el estudio.

Después de eso, se eligen los parámetros de entrada para construir un modelo para predecir la probabilidad de que se atasque una tubería en el campo deseado. Las variables seleccionadas se normalizan y se crean dos bases de datos para la perforación de pozos verticales. Finalmente, se utiliza un método de inteligencia artificial que integra redes neuronales y optimización de enjambre de partículas PSO, (por sus siglas en inglés, PARTICLE SWARM OPTIMIZATION) para predecir la probabilidad de presencia de tiempo no productivo. Este algoritmo de Machine learning utiliza un modelo de redes neuronales basado en PSO. La variable de salida es la probabilidad de un NPT, mientras que las variables de entrada son parámetros de perforación, lodo, geometría e hidráulicos y otros.

1.2 ANTECEDENTES

1.2.1 Antecedentes del área de aplicación

1.2.1.1 *Características del Bloque Sub Andino Sur*

Dunn (1995) menciona que los plegamientos de los anticlinales encontrados pertenecen a un desbordamiento superficial con dos horizontes de elevación interconectados, uno en la formación del Silúrico y el otro en la formación de los monos del Devónico, los pliegues de flexión superan un cambio en la sección estratigráfica.

Para el presente estudio, considerando la complejidad del tema y que la perforación de pozos difiere, así sea en la misma zona se realizara el estudio de la formación Huamampampa del bloque Sub Andino Sur.

Por ejemplo, Montellano (2003) describe las formaciones que se perforaron en el pozo SAL14, donde a los 24 días se cruzó la Formación Tarija a 863 metros y se perforó la Formación Miller a 864 metros donde la perforación avanzó muy rápido y aún a 2,558 metros Pizarras y limolitas fueron encontrados.

Asimismo, Montellano y Abruzzese (2003), resume las actividades de perforación que realiza la empresa PRIDE INTERNATIONAL, SAL14, donde el 2 de mayo de 2003 a las 7:30 p.m. se inició operaciones, luego de 20 días de perforación ya había alcanzado una profundidad de 773.02 metros, fue con lodo aireado llegando a varias formaciones.

1.2.1.2 Estratigrafía

A continuación, se presenta en el siguiente recuadro la estratigrafía con su respectiva descripción del bloque sub Andino Sur (Yacimientos Petrolíferos Bolivianos, 2019).

Tabla 1. 1: Descripción estratigráfica del Bloque Sub Andino Sur

Edad	Formación	Descripción
Devónico	Iquiri	Compuesta por una alternación de lutitas, limolitas y areniscas; el predominio corresponde a lutitas, estimándose en un 60%, las areniscas por lo general son de grano fino a medio, subredondeado, mal seleccionado, porosas a poco porosas, no se han encontrado fósiles se señalan el piso Frasniano, base del Devónico Superior, (Ayaviri, 1967).
	Los monos	Aproximadamente a 8 kilómetros al suroeste de la población de Villamontes. Consiste principalmente de lutitas gris oscuras con subordinación de delgadas capas gris blanquecinas de areniscas cuarcíticas, en especial en su parte superior, existen intervalos arenosos que llegan hasta los 70 m de espesor, que en algunas estructuras son portadores de hidrocarburos. Su

		<p>espesor promedio es de 1.500 metros. (Oblitas et al., 1972).</p>
	Icla	<p>Presentan niveles arcillo-arenoso con facies mayormente pelítica con algún desarrollo de psamitas, los términos intermedios, son mucho más arenosos y limolíticos. Las areniscas que en general son de grano medio y muy silíceas, en espesores de 0.3 a 1 m macizas y poco laminadas, de un espesor: 642 metros, Edad: Gediniano Sup. - Emsiano Inf. (Jiménez & López-Murillo, 1973).</p>
	Santa Rosa	<p>Las Areniscas Basales Santa Rosa están expuestas en un espesor de unos 120 m, no se puede ver la base de esta formación. La parte inferior de las areniscas se presenta estratificada en bancos gruesos con estratificación entrecruzada, hacia arriba esta arenisca pasa a una arenisca arcillosa de colores más oscuros gris verdusco, estratificada en láminas de colores delgados, las areniscas no son fosilíferas, (Ahlfeld & Braniza, 1960).</p>

	Huamanpampa	Constituida por areniscas potentes, de color gris, gris claro, de grano medio a grueso, estratificadas en bancos de 2 metros de espesor, los cuales presentan una alta dureza, y intercalaciones de lutitas limolitas se encuentran abundantes fósiles, hacia la parte alta de la serie arenosa existe una capa delgada de arenisca conglomerádica integrada por rodados de cuarcita gris y cuarzo blanco, bien redondeada, (Ayaviri, 1967)
Silúrico	Tarabuco	Presenta alrededor de 390 m de espesor, en la base se presentan areniscas gris verdosas, de grano fino, limosas, micáceas, en bancos de 0.1 a 0.5 m de espesor, intercalados con areniscas limosas, gris verdosas, micáceas y silíceas, intercaladas con lutitas gris verdosas.
	Kirusillas	Litológicamente esta formación está constituida exclusivamente por lutitas gris oscuras, bien consolidadas micácea, y bituminosas, intercaladas delgadas (40 a 50 cm) de areniscas gris blanquecinas (Suarez & Díaz, 1996)

Fuente: Yacimientos Petrolíferos Bolivianos. Informe litológico del Bloque Sub Andino Sur, 2019

Se tiene por tanto la descripción de cada formación en función de la edad estratigráfica que se ha realizado a lo largo de los años y eso antecede fundamental para poder entender dónde se está llevando a cabo y qué tipo de funciones existen en este bloque. Para entender mejor el orden de los estratos, se muestra la siguiente gráfica (REPSOL, 2020):

Figura 1. 1: Estratigrafía del bloque Sub Andino



Fuente: REPSOL YPF. Informe estratigráfico del Sub Andino Sur, 2020

Se presentan también los espesores de cada estrato en su respectiva estratigrafía:

Figura 1. 2: Presentación de espesores de la estratigrafía del Subandino Sur

ERA	PERIODO	GRUPO	FORMACION	ESPESOR (m)		
CENOZOICO	TERCIARIO	CHACO	EMBORUZU			
			GUANDACAY	2000		
			TARIQUIA	3000		
			YECUA	120		
			PETACA	140		
MESOZOICO	CRETACICO	TACURU	ICHOA	600		
	JURASICO		CASTELLON	700		
			TAPECUA	200		
	JURASICO TRIASICO		BASALTO ENTRE RIOS	84		
	PALEOZOICO	PERMICO	CUEVO	SAN DIEGO	100	
				IPAGUAZU	450	
				VITIACUA	188	
		CARBONIFERO	MANDIYUTI		CANGAPI	400
					SAN TELMO	500
			MACHARETI		ESCARPMENT	500
TAIGUATI					200	
CHORRO	120					
TARIJA	600					
ITACUAMI	130					
TUPAMBI	500					
ITACUA	200					
IQUIRI	700					
DEVONICO		LOS MONOS	1000			
		HUAMAMPAMPA	600			
		ICLA	600			
		SANTA ROSA	600			
SILURICO		TARABUCO	1500			
		KIRUSILLAS	650			

Fuente: Yacimientos Petrolíferos Bolivianos. Informe litológico del Bloque Sub Andino Sur, 2019

1.2.2 Antecedentes la propuesta

YPFB CHACO y otras empresas anexas que pertenecen a la estatal, presentan varias exigencias en el momento de llevar a cabo un informe previo a un proyecto de perforación en una determinada área. En el Anexo A, se puede observar que existen varios requisitos administrativos dentro de los cuales se considera que los tiempos no productivos dentro de una perforación, representan un costo por daño, debido a que es un perjuicio, en virtud a que no avanza en días operativos. Esto quiere decir, que se llega a invertir un determinado monto para la perforación por hora y genera un

desperdicio económico el no poder avanzar en la construcción de un tramo en una determinada estratigrafía.

Entonces es necesario tener una propuesta para poder controlar y predecir la probabilidad de que se presente un NPT durante la construcción de un tramo de perforación en esta zona.

1.2.3 Antecedentes de la investigación

Martínez & Poveda (2021), en su Proyecto de Grado denominado “Optimización en la planeación de pozos por medio de la predicción de tiempos, costos y npt’s, aplicando un modelo de machine learning para la campaña de perforación de castilla y castilla norte 2020”, predijeron los días y NPT’s seleccionando cómo algoritmo el modelo Decision Tree Regressor o árbol de decisiones, obteniendo una precisión de lo ejecutado con respecto a lo pronosticado del 77.1% y 30.72% respectivamente. Por otra parte, para la predicción de costos, seleccionó el modelo de Random Forest Regressor obteniendo una precisión a lo pronosticado del 79.51%. Para este trabajo realizaron la simulación con el software Python (Martínez & Poveda, 2021).

Ayala (2017) en su trabajo de investigación “Análisis técnico económico del tiempo no productivo (NPT) en las operaciones de perforación del campo Oso”, realiza un análisis técnico de los NPT's, determinándose las causalidades de estos y presentando una propuesta para su mitigación. Posteriormente, realizan la evaluación económica de costos asociados al NPT y generan y proponen algunas recomendaciones para evitar estos tipos de eventos (Ayala, 2017)..

Ojeda (2021) en su proyecto de grado denominado como “Generación de un modelo predictivo para eventos de pega de tubería en pozos de petróleo” realizó un análisis estadístico no estructurado con el software libre llamado Web Plot Digitizer para determinar en qué tiempo se podría presentar un posible evento de pega de tubería durante la perforación de pozos (Ojeda Vargas, 2021).

1.3 PLANTEAMIENTO DEL PROBLEMA

1.3.1 Identificación del problema

El peor factor que se presenta dentro de la perforación en la industria petrolera es la pérdida de tiempo durante este proceso, como ser atascamiento de la herramienta, plegamiento de la tubería, pérdida de lodo de perforación y otros importantes como el derrumbe. Por tanto, estas actividades llegan a ser costosas y consumen mucho tiempo y muchas veces generan riesgo y peligro.

La causa principal para que se genere un NPT durante la perforación de un pozo es debido a las altas presiones y variación de estratos que se presentan en un determinado reservorio objetivo, lo cual genera problemas de atascamiento, pérdida de lodos y otros cuando se va construyendo un pozo exploratorio. Según Repsol YPF (Ver Anexo B), el bloque sub Andino Sur ha presentado problemas durante el desarrollo de perforación de pozos y se puede resumir en la siguiente tabla:

Tabla 1. 2: Problemas identificados durante el desarrollo de pozos en el Sub Andino Sur

Estrato	Caracterización	Problemas potenciales
Carbonífero	Altos buzamientos Abrasividad Alta resistencia a la compresión Atascamientos	Estabilidad de pozo Pérdidas de fluidos Baja ROP Alta solicitud de herramientas
Devónico – Los Monos	Altos buzamientos Alta presión de formación Lutitas dispersables laminadas. Formación altamente micro fracturada	Inestabilidad del pozo debido a fuerzas tectónicas y presencia de micro fracturas. Inestabilidad debido a prolongados tiempos de hueco abierto

Devónico Huamanpampa	–	Altos buzamientos Alta presión de formación Formaciones altamente fracturadas	Estabilidad de pozo Atascamientos Abrasividad Break outs Aprisionamiento
-------------------------	---	---	--

Fuente: Elaboración propia en base a informe técnico de problemas realizado por REPSOL YPF, 2020

Es necesario entonces contar con una herramienta que permita predecir la probabilidad de que se generen estos NPT (como ser atascamiento de tubería, atascamiento de las herramientas, pérdida de lodo, etc.) en el proceso de planificación de pozos exploratorios en el bloque sub andino Sur a través de parámetros de pozos que ya se han perforado.

1.3.2 Formulación del problema

En función a la anterior explicación y análisis se puede formular el siguiente problema:

¿De qué manera se podría predecir los tiempos no productivos en la perforación de pozos exploratorios en el Sub Andino de Bolivia?

1.4 OBJETIVOS

1.4.1 Objetivo general

Estimar los tiempos no productivos en la perforación de pozos exploratorios en el Sub Andino de Bolivia, aplicando el algoritmo de Aprendizaje automático con datos estadísticos.

1.4.2 Objetivos específicos

- Utilizar la tecnología de inteligencia artificial de red neuronal para predecir la probabilidad de NPT en la planificación de pozos en el sub Andino Sur.

- Crear una base de datos para el modelo propuesto, recopilando las características del lodo, la geometría, los parámetros hidráulicos y de perforación de los informes de perforación diarios de los pozos ya perforados en el Sub Andino sur.
- Determinar los parámetros de perforación mediante la simulación del modelo propuesto con datos de pozos con y sin NPT para la planificación de futuros pozos aplicando el software Matlab.
- Desarrollar un plan de riesgos a partir de la simulación para evitar futuros NPT's en la planificación de nuevos pozos en el bloque Sub Andino.
- Realizar un análisis de factibilidad técnico - económica del Proyecto.

1.4.3 Desarrollo de las actividades

A continuación, se presenta el cuadro donde se explica el desarrollo de las actividades en función a los objetivos específicos planteados.

Tabla 1. 3: Desarrollo de las actividades

OBJETIVOS	ACTIVIDADES
Utilizar la tecnología de inteligencia artificial de red neuronal para predecir la probabilidad de NPT en la planificación de pozos en el sub Andino Sur	Desarrollo del programa de inteligencia artificial de red neuronal para predecir la probabilidad de NPT en Matlab.
Crear una base de datos para el modelo propuesto, recopilando las características del lodo, la geometría, los parámetros hidráulicos y de perforación de los informes de perforación	Recopilación de características del lodo.
	Recopilación de características de atascamiento de herramientas.
	Recopilación de características de atascamiento de tubería.

diarios de los pozos ya perforados en el Sub Andino sur.	Recopilación de características de daño de pozo.
	Recopilación de características de la geometría de pozos.
	Recopilación de características los parámetros hidráulicos
Determinar los parámetros de perforación mediante la simulación del modelo propuesto con datos de pozos con y sin NPT para la planificación de futuros pozos aplicando el software Matlab.	Determinación de nuevos parámetros mediante la simulación del modelo con datos de pozos con NPT
	Determinación de nuevos parámetros con datos de pozos sin NPT
Desarrollar un plan de riesgos a partir de la simulación para evitar futuros NPT's en la planificación de nuevos pozos en el bloque Sub Andino.	Desarrollo de Plan de riesgos por tramos a partir de la simulación
Realizar un análisis de factibilidad técnica y económica del proyecto.	Realizar una evaluación técnica del proyecto observando aspectos cualitativos
	Realizar una evaluación de económica observando la relación de costo beneficio y la rentabilidad del mismo

Fuente: Elaboración propia, 2023

1.51.7 JUSTIFICACIÓN

1.5.1 Justificación técnica

Para poder controlar de manera eficiente los tiempos no productivos durante la planificación de un pozo exploratorio en el bloque Sub Andino, es necesario tener parámetros operativos eficientes con rangos numéricos, y es lo que ofrece este estudio ya que cuantificará los valores máximos y mínimos con los que se debe trabajar para

evitar atascamientos de herramientas y tuberías, pérdida de fluidos de perforación y otros que hacen que el trabajo de perforación sea ineficiente.

1.5.2 Justificación económica

Según las normativas de contratación de servicios de perforación que plantea YPFB y puede observarse en anexos A, los NPT's generan costos operativos debido a los daños financieros y pérdida de tiempo que generan en una perforación y representa un derroche económico para la empresa. Por tanto, al poder controlar esos problemas se puede evitar daños económicos y generar un ahorro en este proceso de perforación y en la planificación de pozos exploratorios.

1.5.3 Justificación ambiental

Mediante el presente proyecto con la predicción de tiempos no productivos en la perforación de pozos exploratorios en el sub andino de Bolivia, aplicando el algoritmo PSO se reducirá los impactos ambientales de la actividad de Perforación. También cabe recalcar y recordar de que el proyecto no genera ningún impacto ni daño directo ya que no se genera ningún impacto ambiental, ya que el proyecto es analítico y no requiere de ninguna implementación en campo

1.5.4 Justificación teórica

El desarrollo de modelos predictivos para el control de tiempos no productivos en la planificación de pozos exploratorios en el Sub Andino será también como una herramienta fundamental para cualquier tipo de perforación en el futuro y una base teórica para desarrollar otros modelos en el futuro logrando así que todo trabajo de perforación sea eficiente por parte de la universidad para cualquier empresa petrolera que lo necesite.

1.6 ALCANCES

1.6.1 Alcance temático

Los temas que se logran alcanzar en este proyecto, principalmente son los temas de perforación en pozos verticales, el tema de tiempos no productivos (NPT)¹, modelos matemáticos y simulación.

El pilar fundamental de aplicación práctica es también el modelado a través del uso de software de Matlab para realizar la simulación del algoritmo en Machine learning y el sistema PSO que viene dentro paquetes ya descargables y fáciles de manejar para poder predecir las probabilidades que se presenten los NPT en determinados intervalos de perforación a través de los registros de la zona en estudio.

Se propondrán modelos basados en autores e investigaciones que aún no fueron aplicados en Bolivia.

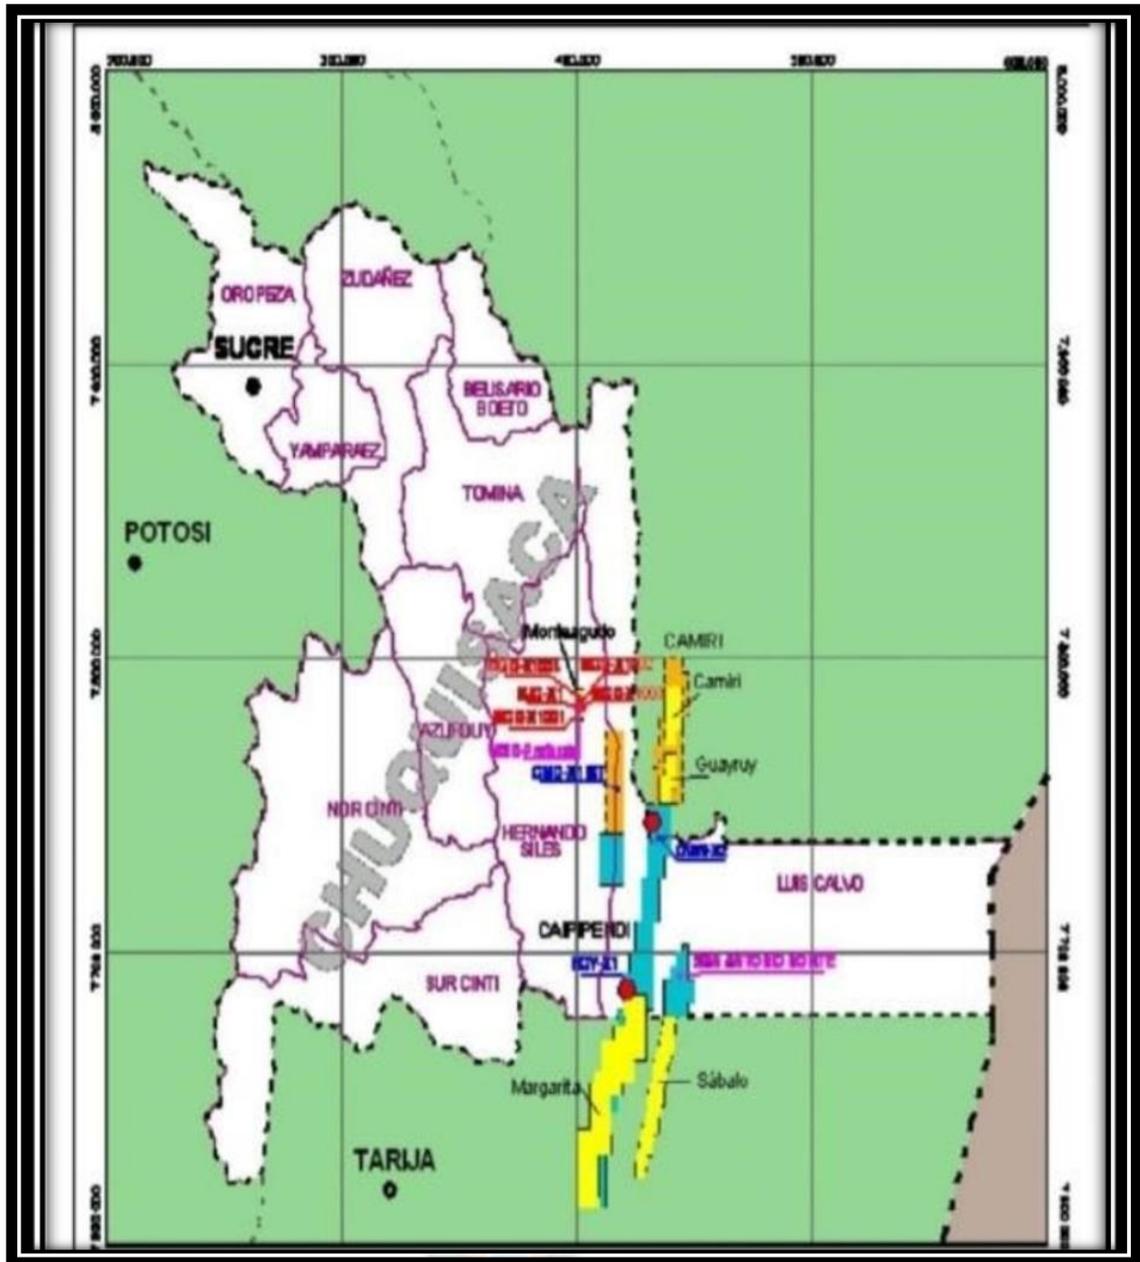
1.6.2 Alcance geográfico

El proyecto será aplicado en la región del Sub andino Sur y Pie de Monte de la Cuenca de Tarija, en Bolivia, que abarca un área cercana a los 100,000 km².

El sector analizado comprende, desde la Faja Corrida Externa y el Pie de Monte ubicado entre el Codo de Santa Cruz al Norte y la región del límite político Bolivia – Argentina hacia el Sur. Se excluye de este análisis la zona de la cuenca denominada Boomerang, situada al Norte del Codo de Santa Cruz.

¹ Del inglés No Productive Time = NPT; que significa “Tiempos no productivos”

Figura 1. 3: Ubicación del Área Sub Andino Sur



Fuente: <http://google.earth.com/>

1.6.3 Alcance temporal

El proyecto se realizará este año con datos de gestión de 2020 a 2021.

CAPÍTULO 2: TIEMPOS NO PRODUCTIVOS EN LA PERFORACIÓN DE POZOS PETROLEROS

2.1 TIEMPOS DE LA PERFORACIÓN

El tiempo de perforación está ligado al registro de tiempo de perforación que consiste en la tabulación cronológica o trazado de la tasa de penetración de las rocas del subsuelo por la broca rotatoria. Estos tiempos son estimados y controlados antes y durante el proceso de perforación (Martínez & Poveda, 2021).

El tiempo en el que las operaciones de perforación no se producen, es decir, al extraer del fondo del agujero la sarta de perforación y reanudar las operaciones a la misma profundidad (Vargas & Zuly, 2018).

Las compañías de petróleo y gas gastan alrededor de \$ 20 mil millones anuales en perforación. Pero, no todo ese dinero está bien gastado. Una parte importante, alrededor del 15%, se atribuye a pérdidas. Estas pérdidas se denominan tiempo improductivo (TNP).

El tiempo improductivo (NPT) no tiene una definición estándar. Las organizaciones definen NPT de una manera que se adapte a su propósito. Rabia (2001) define NPT como el tiempo que tarda cualquier operación de rutina o anormal que se lleva a cabo como resultado de una falla o un evento que hace que se detenga la operación de perforación.

Nabaei et. hacia. (1989) definen la NPT como la incluido como NPT en esta definición. En una edición del contratista de perforación (Hsieh, 2010), NPT se describe como cualquier cosa que sucede fuera del plan original. Esta medida de NPT incluye cualquier tiempo dedicado a una actividad por encima del tiempo previsto para esa actividad. Por ejemplo, un viaje necesario, pero no planificado califica como NPT.

El NPT es el tiempo que se gasta en no construir el pozo. Esto no incluye operaciones tales como correr el revestimiento, cementar el revestimiento, registrar el pozo, etc. Esos son todos necesarios para el proceso de construcción. Sin embargo, cualquier cosa que no contribuya a la construcción del pozo sería NPT. Esto incluiría reparaciones de plataformas, espera de logística, clima, etc. También hay otros eventos, llamados bonita manera de decir que algo ha ido mal. Puede ser impulsado por la plataforma y las personas o por la Madre Naturaleza (Martínez & Poveda, 2021).

Al buscar formas de reducir el NPT, una de las soluciones más obvias es realizar un análisis de causa raíz. Evitar los problemas de perforación reduce los costos de búsqueda y desarrollo y permite que los miles de millones de dólares que ahora se gastan en pérdidas se gasten mejor en construir y reemplazar reservas.

2.2 CLASIFICACIÓN Y TIPOS DE PERFORACIÓN

La única forma de verificar la existencia de hidrocarburos en el subsuelo, aun después de explorar su probable ubicación es perforando un pozo.

Una vez que los yacimientos de gas o petróleo son ubicados, se procede a la perforación de pozos exploratorios o de desarrollo. Bajo distintos procedimientos, la perforación del subsuelo se practica desde hace siglos. La mecánica empleada en los primeros tiempos y su desarrollo se describe a continuación:

2.2.1 Perforación rotatoria

La perforación de un pozo petrolero se realiza con una barrena de acero cortante enroscada en el extremo inferior de una tubería de acero (sarta de perforación), la cual se hace rotar a una velocidad determinada, con una fuerza de apoyo sobre la tubería de tal manera que se va profundizando el agujero, conectando y enroscando más tubería por el extremo superior.

2.3 TIPOS DE EQUIPOS DE PERFORACION

Se adaptan según las siguientes áreas de perforación:

1. Terrestres convencionales
2. Terrestres auto transportables
3. Lacustres
4. Marinos de plataforma auto elevables
5. Marinos de plataforma semi-sumergibles
6. Marinos flotantes (barco perforador)

2.2.2 Equipos de perforación terrestres

Son los siguientes:

- Carga: Ligera/pequeña, Mediana, Pesada y ultra pesada.
- Profundidad de perforación: hasta de 20,000 ft.
- Equipo ligero: mástil o torre montada sobre camión (fácil y rápido traslado)
- Subestructura (Transportada con camiones y grúas)
- Mástil convencional y telescópico.
- Ligero (5,000 ft), mediano (10,000 ft) y pesado (20,000 ft)

2.2.3 Equipos terrestres auto transportables

Están constituidos por un conjunto de malacate-motores; montados sobre un remolque que se auto transporta. Así cuenta con mayor facilidad de transporte de una localización a otra, pero con menor capacidad en la profundidad de perforación.

2.2.4 Equipos de Perforación Lacustres

Estos equipos de perforación sumergibles son usados en aguas muy someras y protegidas de hasta 15 metros de profundidad. El equipo es llevado a flote hasta la localización como una barcaza convencional y se lastra para sumergirlo hasta que descansa en el fondo lacustre. El casco inferior está diseñado para soportar el peso total de la unidad más la carga de perforación.

2.2.5 Equipos de perforación Marinos (Plataforma autoelevable Jack Up)

Esta es una plataforma especial usada para la perforación y reparación de pozos. Tiene una capacidad de moverse de una localización a otra, por medio de remolcadores. Una vez que se encuentra en la posición deseada, las piernas son bajadas hasta alcanzar el fondo marino; entonces la cubierta es elevada más allá del nivel del agua.

- Profundidad de agua hasta 600 ft.
- Profundidad de perforación hasta 35,000 ft.
- Remolcado con barco de una localización a otra, con plataforma al nivel del mar.
- La mayoría tiene 3 columnas, pero existen también de 4.
- Mástiles telescópicos y convencionales.

2.3 BARRENAS

Herramienta de corte localizada en el extremo inferior de la sarta de perforación que se utiliza para cortar o triturar la formación durante el proceso de perforación rotatoria.

Su función es perforar los estratos de la roca mediante el vencimiento de su esfuerzo de compresión mediante la rotación de la barrena.

Para realizar la operación, las barrenas funcionan con base en dos principios esenciales:

- Fallar la roca venciendo sus esfuerzos de corte.
- Fallar la roca venciendo esfuerzos de compresión.

2.3.1 Principios de corte (Principios de ataque)

- De PDC-Debasta
- De Conos – Tritura
- De Diámetros Naturales – Abre Surcos

2.3.2 Características de las barrenas

2.3.2.1 *Cono giratorio (tricónicas)*

- Tres conos cortadores que giran sobre su propio eje.
- Pueden tener dientes de acero fresado o inserto de carburo de tungsteno.
- Poseen toberas que envía el fluido de perforación a alta velocidad contra el fondo del pozo para remover y levantar las partículas a medida que la barrena corta el terreno.
- La estructura de corte está montada sobre cojinetes.

2.3.2.2 *Cortadores fijos*

- Carecen de partes móviles.
- El cuerpo fijo de la barrena puede ser de acero o de carburo de tungsteno.
- Son fabricados con diamante natural o sintético.

- La dureza externa y la alta conductividad térmica del diamante lo hacen un material con alta resistencia para perforar en formaciones duras a semiduras.

2.3.2.3 Especiales

- Se utilizan para operaciones específicas; los materiales que las conforman son los mismos empleados en las tricónicas y fijas.
- La diferencia en algunas veces es el diseño de las mismas y su función que se les da. Podemos mencionar: barrenas ampliadoras, barrenas para cortar TR's, barrenas con aplicación de tubería flexible, coronas para extraer núcleos, etc.

2.3.2.4 Tipos de barrenas de cortadores fijos

- Barrenas de Diamante Natural.- el uso es limitado en la actualidad, salvo en casos especiales para perforar formaciones muy duras y cortar núcleos de formación con coronas de diamante natural.
- Barrenas de Diamante Térmicamente estable (TSP).- Son usadas para perforar rocas duras como caliza dura, basalto y arenas finas duras. Son un poco más usadas para la perforación convencional que las de diamante natural.
- Barrenas de compacto de Diamante Policristalino (PDC).- Su diseño de cortadores está hecho con diamante sintético en forma de pastillas, montadas en el cuerpo de los cortadores de la barrena.

2.3.2.5 Clasificación por uso

- Barrena de perforación.- Se comprende de toda la gama de diferentes barrenas empleadas para profundizar el pozo.

- Barrenas saca núcleos.- Comprende a las barrenas que poseen una corona que permite la obtención de núcleos con la perforación.
- Barrenas de perforación de cortadores fijos multi-hojas.- Diseñadas de esta manera para la apertura de agujeros; los cortadores se distribuyen en todas las hojas.
- Barrenas de perforación de cortadores fijos de perfil redondo.- Poseen una distribución de los cortadores con el objetivo de acelerar la velocidad de penetración, así como disminuir la resistencia de corte; se aplica para rocas de dureza media suave.
- Barrenas escariadoras.- Se aplican al fresado y perforación en formaciones de roca media-dura, con características de buena capacidad de orientación, estable, y tiene resistencia a la abrasión.
- Barrenas con 3 hojas.- Se aplica para formaciones de roca mediano-dura. Acelera el ritmo de penetración y genera alta eficiencia de penetración. Permite un flujo mas fluido del lodo a través de los canales de flujo de la barrena.
- Barrenas desviadoras.- son barrenas que se utilizan para desviar el pozo en formaciones duras o abrasivas.
- Barrenas para cortar TR's.- Se utilizan para cortar secciones de tuberías de revestimiento o pescados.
- Barrenas ampliadoras.- Se utilizan para incrementar el diámetro del agujero o para trabajar con diámetros especialmente grandes.
- Barrena para perforar con aire.- Son barrenas diseñadas con toberas especiales para la perforación con aire como medio de circulación.

2.4 DAÑOS A LA FORMACIÓN POR LA PERFORACIÓN

Los sólidos del fluido de perforación pueden obstruir el área de flujo o bien las fracturas de porosidad secundaria y también inducida.

El filtrado del fluido dentro de las zonas productoras causa:

- Cambio de la mojabilidad natural de la formación provocando un bloqueo por emulsión o agua.
- Hinchamiento, dispersión y migración de arcillas hacia espacios porosos bloqueando la permeabilidad.

También se daña a la formación con la operación de cementación de las tuberías de revestimiento:

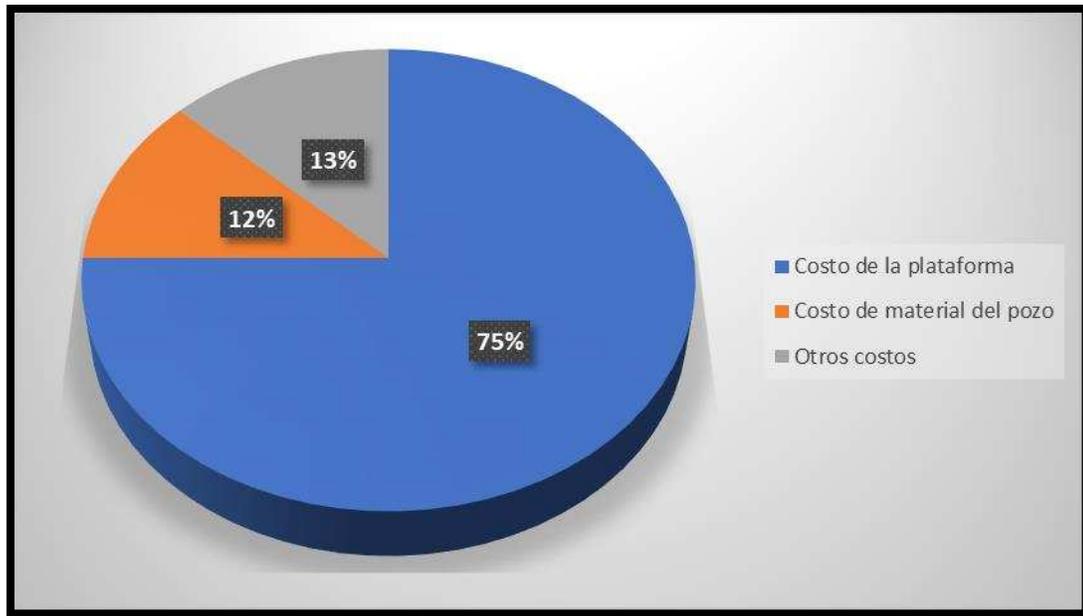
- Los sólidos del fluido y el cemento pueden obstruir la porosidad primaria y secundaria así como las fracturas inducidas.

Los sistemas con agua y químicos usados para limpiar el pozo (baches, lavador y separador) bombeados delante del cemento pueden también alterar las arcillas de la formación productora.

2.5 PROBLEMAS ASOCIADOS A LA PÉRDIDA DE TIEMPO EN LA PERFORACIÓN

Según Vinod (2013) los principales costos asociados a la perforación de un pozo se deben principalmente a los costos de los equipos de perforación en los que se consideran los costos ineficientes por varias causas que se explican a continuación (Fig. 2.1).

Figura 2. 1: Componentes principales del costo del pozo¹



Fuente: Elaboración Propia, (En base a Vinod, 2013)

Los principales desafíos de las operaciones de perforación o problemas asociados a la pérdida de tiempo, son evitar pérdidas de equipos de perforación o continuidad del proceso de perforación, es decir, tiempo improductivo (NPT) debido al impacto en el costo total de un proyecto.

Por ejemplo, éstos desafíos son aún mayores cuando se perfora en aguas profundas o a través de capas de sal debido a las condiciones particulares de altas presiones y formaciones móviles. Al perforar a través de la capa de sal, existe un grado de incertidumbre relacionado con el movimiento de la sal (halocinesis) y también una predicción incorrecta de la litología y las presiones intersticiales; de hecho, el flujo de plástico bajo las temperaturas y presiones del subsuelo junto con la baja permeabilidad presentan desafíos únicos para la perforación. operaciones como peligros de formaciones salinas móviles.

¹ Other costs = Otros Costos; Well material cost = Costo de material de pozo; Rig Cost = Costo de plataforma

El tiempo improductivo representa altos costos, 150 millones de dólares por año para cada contratista de perforación, lo cual se debe a estas categorías de problemas en orden de ocurrencia (AADE group, 2015).

- Falla del equipo de superficie
- Falla del equipo auxiliar
- Otro (no planificado, en espera, desconocido)
- Problemas de fondo de pozo relacionados con el entorno físico
- Reparaciones de plataformas
- Clima
- Falla del equipo de fondo de pozo
- Tubería atascada
- Accidente e incidente.

2.6 CLASIFICACIÓN DE TIEMPOS DE PERFORACIÓN

2.6.1 Tiempo programado

Es en el que dura una perforación de tramos en función a la profundidad y la velocidad de las barrenas de perforación. Ese tiempo está programado debido a los cálculos que se realizan en función de la velocidad de perforación. (Barakat, 2018)

2.6.2 Tiempo productivo

Es aquel tiempo que se da durante la perforación y no ocurre ninguna falla ni problema, es decir que se va cumpliendo el tiempo programado. (Barakat, 2018)

2.6.3 Tiempo no productivo

El tiempo no productivo es todo lo contrario al anterior concepto, es decir cuando no se cumple el tiempo programado de perforación por algún inconveniente o falla en los equipos o en el ambiente donde se desarrolla la perforación.

2.6.4 Tiempo invisible

Son los tiempos donde no se lleva a cabo ninguna operación, pero tampoco se presenta ningún inconveniente es decir tiempos de espera de instalación de equipos, tiempos extendidos de descanso por algún incidente. Los tiempos invisibles no están enlazados directamente a los tiempos no productivos.

2.7 EL PROBLEMA PRINCIPAL DE LOS TIEMPOS NO PRODUCTIVOS O NPTS

El NPT se define como el momento en que la operación de perforación cesa de forma no planificada o cuando la tasa de penetración de perforación se vuelve excesivamente baja (Dew y Childers 1989). Dadas las colosales inversiones en las empresas de perforación de petróleo y gas, ya sea en tierra o en alta mar, el tiempo de perforación se ha vuelto un reflejo íntimo de sus costos operativos. Por lo tanto, reducir el NPT debería mejorar el rendimiento de la perforación y reducir el costo del pozo para ahorrar dinero.

El concepto NPT comenzó en la década de 1960, y desde entonces surgieron muchos estudios y enfoques en un intento de controlar el tiempo perdido a valores aceptables. En Estes (1971), establece la estandarización de la selección de bits para disminuir el NPT utilizando la técnica de análisis de Pareto (regla 80/20) para lograr los objetivos del estudio. El principio de Pareto establece que “para muchos resultados, aproximadamente el 80% de las consecuencias provienen del 20% de las causas” (Pareto y Page 1971). Anteriormente, este principio ha tenido muchas aplicaciones en el control de calidad donde se creó por primera vez.

Tal hallazgo le permitió concentrarse en los problemas de perforación más rentables. Posteriormente, Pérez et al. (1990) describieron una aplicación exitosa de la metodología de gestión de calidad total para reestructurar y mejorar la organización de perforación, generar soluciones para mejorar la eficiencia de perforación y resolver problemas operativos encontrados en los esfuerzos iniciales de desarrollo de un campo profundo en tierra en Venezuela. Luego, Bradley et al. (1991) analizaron la distribución del tiempo de perforación para el área del Golfo de México desde 1985 hasta 1990, enfocándose en el costo y las causas de los incidentes de tubería atascada. Sin embargo, Kadaster et al. (1992) establecieron un enfoque sistemático (que se extiende a más de un subsistema de perforación) para analizar, evaluar, mejorar y volver a aplicar el lodo de perforación, las barrenas y las técnicas hidráulicas para reducir el costo por pie durante la operación de perforación.

En 2004, Tibiletti et al. Subrayó la importancia de minimizar el TNP. En este trabajo, se presentó un estudio de caso real de Rashid Petroleum Company (Mar Mediterráneo, Egipto) para reducir el NPT en pozos submarinos de alto costo en aguas profundas. El estudio incluyó una comparación entre el tiempo de operación normal y el NPT para mostrar cómo el NPT tiene un impacto en el desempeño del proyecto. Además, Gala et al. (2010) revisaron la relación entre el NPT y los riesgos de perforación. Desarrollaron procesos de evaluación de ingeniería que ayudaron a utilizar las mejores herramientas y técnicas de perforación disponibles para reducir el NPT del 40 al 10 %.

Además, Everage et al. (2011) revisaron y analizaron un estudio de caso real sobre uno de los incidentes NPT de tubería de perforación twist-off. En este estudio se consideraron los principales parámetros de riesgo (probabilidad y costo como medida de severidad) sin nombrarlos. Este trabajo incluyó un estudio de caso sobre el NPT excesivo debido a fallas por fatiga de peso normal y peso pesado al perforar pozos horizontales en comparación con los pozos verticales. Los resultados del estudio mostraron que las fallas de la tubería de perforación pesada se redujeron en un 47%, cuando se aplicaron los estándares del Instituto Americano del Petróleo. El concepto

de indicadores clave de rendimiento (KPI) también desempeñó un papel importante en el apoyo al rendimiento de la perforación y la evaluación del NPT (Hernández y Torres 2011). Los pasos de revisión del desempeño incluyen una acción inmediata para el proceso de toma de decisiones, una aplicación de cuadro de mando integral para la discusión requerida, una asignación de tiempo de revisión periódica y un historial de desempeño. Los KPI reflejan el desempeño de un proceso en el logro de sus objetivos y estándares.

El objetivo principal del uso de KPI es reducir los costos de perforación, eliminar los riesgos de perforación y mantener la integridad operativa (Hernández y Torres 2011). Sin embargo, estos enfoques se centraron en el valor temporal de la NPT sin introducir la influencia de las frecuencias o las probabilidades de que sucediera en el costo de la NPT durante un período de tiempo común con el fin de calificar comparativamente el desempeño del equipo de perforación en cuanto a la NPT en un número seleccionado de las principales operaciones de perforación.

La introducción de la noción de probabilidades de ocurrencia tiende a otorgar pesos a la ocurrencia de los respectivos valores de pérdidas, y cuando se suman las severidades (representadas por el costo), se introduce el riesgo en la decisión que da cuenta de la incertidumbre de ocurrencia. Hurtado y Redlinger (2016) revisaron varias aplicaciones de campo de NPT y presentaron una correlación entre la eficiencia de perforación y las técnicas HSE probadas con éxito. Demostraron que la reutilización de técnicas probadas de HSE para su uso fuera de la seguridad reduce el NPT y mejora la eficiencia de la perforación. Recientemente, el RM se ha convertido en un estilo de gestión propicio para la mejora continua, la calidad total y, en general, la excelencia empresarial.

81

El RM es un proceso organizado de identificación, evaluación y manejo de todos los riesgos para llevar los eventos no deseados, en la vida o en los negocios, a valores aceptables o tolerables. En 2004, Main presentó los fundamentos de los conceptos de evaluación de riesgos. Posteriormente, Khalaf y Abu El Ela (2008) revisaron los

fundamentos de la gestión de riesgos y demostraron que acoplar la probabilidad de que ocurra un evento no deseado y sus consecuencias puede servir como medida para optimizar las operaciones y es una forma de organizar, reconocer, evaluar, elegir, y ejecutar actividades para el control de pérdidas y desperdicios. Como tal, RM tiene aplicaciones en el análisis de perforación-NPT. La estructura de la administración de peligros tiene siete fases:

- (1) Definir el problema y ponerlo en contexto
- (2) Analizar los riesgos asociados con el problema en fases
- (3) Examinar opciones para abordar los riesgos
- (4) Tomar decisiones sobre qué opciones implementar
- (5) Tomar medidas para implementar las decisiones
- (6) Realizar una evaluación de los resultados de la acción
- (7) Documentar el proceso (Barakat, 2018)

Es claro que se ha intentado poco trabajo de investigación para extender los conceptos de administración de peligros o la calidad total (TQ) a la NPT en la operación y rendimiento de la perforación. Además, también se ha tratado de utilizar los conceptos de gestión de riesgos para evaluar el rendimiento de los equipos de perforación en un pequeño trabajo de investigación. Por lo tanto, en este proyecto se plantea controlar los NPT a través de la predicción con Machine learning que se detalla en el siguiente capítulo.

CAPÍTULO 3: ALGORITMOS DE APRENDIZAJE AUTOMÁTICO COMO METODOLOGÍA PARA PREDICCIÓN DE NPT'S

3.1 REDES NEURONALES DE INTELIGENCIA ARTIFICIAL

3.1.1 Big Data

El Big Data puede definirse como los datos que contienen una mayor variedad y que se presentan en volúmenes crecientes y una velocidad superior. El big data trabaja con todo tipo de datos, ya sea estructurados, no estructurados y semiestructurados provenientes de correos electrónicos, redes sociales, mensajería instantánea, imágenes y sensores de máquinas.

Las denominadas 4V's: Velocidad, veracidad, velocidad y variedad es parte fundamental para que la información sea considerada como *Big Data*, además de:

- Volúmenes extremadamente largos de datos.
- Habilidad de transferir datos a alta velocidad.
- Constante expansión con variedad de datos.
- Veracidad en los datos para que estos puedan representar la verdad.

3.1.2 Minería de datos

La minería de datos es la conjunción de la Estadística y el *Big Data*. La misma está basada en los principios básicos de la estadística. Puede definirse como el proceso de explorar y analizar grandes cantidades de datos para descubrir patrones entre ellos, a través de programas de búsqueda e identificación de patrones y relaciones globales.

Un ejemplo de la aplicación de la Minería de Datos es el siguiente: Suponga que un mercadólogo está interesado en conocer las características de las personas que respondieron a una promoción contra aquellos que no respondieron a ésta, la Minería

de Datos se utilizaría para extraer de los datos las diferencias entre las dos clases y analizar cada una de sus características.

3.2 DEFINICION DE MACHINE LEARNING

3.2.1 Definición

Está claro que el ser humano necesita buscar patrones para comprender el mundo que le rodea y anticipar ciertos comportamientos. El aumento de las interacciones entre usuarios y sistemas está generando grandes volúmenes de datos de los cuales se esperan obtener patrones que permitan predecir resultados o comportamientos con el mínimo error. (<https://datascientest.com/es/machinelearning-definicion-funcionamiento-usos>)

En los últimos años, se están empleando diferentes técnicas computacionales y entre ellas destaca, el denominado “*Machine Learning*” o aprendizaje automatizado, un área de la inteligencia artificial que es cada vez más importante en todos los sectores, y en específico en la industria hidrocarburífera, en numerosas aplicaciones en diferentes bloques de la industria.

El autor Alogos (2018) destaca que con frecuencia se emplean indistintamente conceptos como ciencia de datos, minería de datos, aprendizaje automático o inteligencia artificial.

Cuando se habla de *Machine Learning* se suele usar para referirse a la inteligencia artificial (como se había mencionado anteriormente el ML es una subdivisión de la IA). Lo que es pertinente destacar es que el *Machine Learning* se centra en desarrollar sistemas que aprenden o mejoran el rendimiento, en función a los datos ingresados o coloquialmente, que se consumen. (<https://www.oracle.com/es/datascience/machine-learning/what-is-machine-learning/>)

El *Machine Learning* es una técnica que se encuentra asociada a la detección automática de patrones de gran relevancia dentro de un gran conjunto de datos.

En los últimos años, se ha convertido en una herramienta muy común en prácticamente todas las tareas que requieren extraer información a partir de grandes cantidades de datos (Shwartz & Shai, 2014).

Algo que debemos de denotar en nuestro día a día, es que la tecnología basada en el *Machine Learning* ya se encuentra presente entre las actividades cotidianas como ser: el filtrado de correos electrónicos, los sistemas de recomendaciones, la detección facial y el reconocimiento del habla en el *smartphone*, la detección y previsión del tiempo atmosférico, la consulta del tráfico en la carretera, entre otros.

Es por la complejidad de todas estas aplicaciones, que el ser humano no es capaz de programar una serie de especificaciones concretas para la realización, completación o absolución de dichas tareas, sino que tiene que dotar a las propias computadoras con la habilidad de aprender de la experiencia y de adaptarse a las nuevas situaciones. (Shwartz & Shai, 2014)

3.2.2 Conceptos previos del Machine Learning

El *Machine Learning* se fundamenta en las matemáticas, la estadística y la computación. Los desarrollos en computación no llegaron hasta la década de 1940, pero antes de ese momento hubo varios métodos y técnicas matemáticas y estadísticas que sirvieron de base para lo que hoy se conoce como *Machine Learning*: el Teorema de Bayes, el ajuste por Mínimos Cuadrados y las Cadenas de Márkov.

Entre los pioneros del tema *Machine Learning*, podemos destacar a Samuel (1950), que definió al *Machine Learning* como «el campo de estudio que da a las computadoras la habilidad de aprender sobre algo para lo que no han sido explícitamente programadas».

Otro pionero Mitchell (1997) propuso que un problema de aprendizaje bien planteado se define de la forma siguiente: “un programa aprende de la experiencia E con respecto a una tarea T y a un rendimiento P, si el rendimiento medido por P en la tarea T mejora con la experiencia E”. Tomando como ejemplo el programa de aprendizaje del juego de las damas: la tarea T es el jugar a las damas, el rendimiento P se mide con el porcentaje de juegos ganados contra oponentes, y la experiencia E es el jugar contra sí mismo a modo de entrenamiento (Mitchell, 1997).

Los subcampos de la inteligencia artificial son aquellos que se especializan en imitar una parte concreta del sistema cognitivo humano y de sus comportamientos: el Machine Learning es el encargado del reconocimiento de patrones y del aprendizaje; los sistemas expertos se ocupan de la toma de decisiones; los sistemas de búsqueda y planificación eligen la secuencia más adecuada de pasos a seguir para resolver un problema; el reconocimiento del habla y el procesamiento del lenguaje natural analizan y tratan la información recibida a través del lenguaje humano para posibilitar la comunicación; la percepción (como la visión artificial) permite conocer y sentir lo que hay alrededor; y la robótica transforma las decisiones en movimientos (Russell & Norvig, 2008)

Varios autores sugieren que la Inteligencia Artificial forma parte de la ciencia de datos (*Data Science*). Esta se define como la encargada de analizar y revelar con datos lo que hay detrás de fenómenos naturales, humanos y sociales desde un punto de vista multidimensional, flexible y dinámico.

3.3 FUNDAMENTOS DEL MACHINE LEARNING

Para facilitar la comprensión del lector, es necesario presentar los fundamentos para comprender la forma en la que las máquinas aprenden. Para ello es pertinente presentar los conceptos de: varianza, sesgo, sobreajuste y el subajuste.

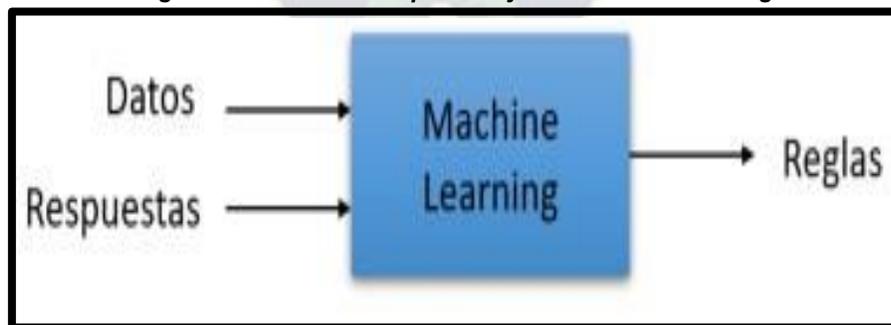
3.3.1 El aprendizaje

En un sistema de Machine Learning, el aprendizaje consiste en el ajuste de los parámetros de un modelo en función a los datos que va recibiendo este. Este conjunto de datos recibe el nombre, como ya lo habíamos mencionado en un punto anterior, de data set, el cual contiene variables independientes como dependientes. Las variables independientes son aquellas columnas de la data set usadas por el algoritmo para generar un modelo que prediga lo mejor posible las variables dependientes. Por otro lado, las variables dependientes son las columnas de la data set resultado de una correlación entre las variables independientes (Russell & Norvig, 2008).

La ventaja del Machine Learning es que estas reglas pueden aplicarse a diferentes datos de entrada para producir respuestas que han sido generadas automáticamente por lo que el sistema aprendió y no por las instrucciones generadas por un humano (Chollet, 2017)

La figura 3.1 representa el aprendizaje utilizando *machine learning*.

Figura 3. 1: Método de aprendizaje del machine learning



Fuente: Hozz, *Machine Learning For Beginners*, Mc Graw Hill, 2015

El modelo debe estar lo suficientemente ajustado a los datos de entrada, pero también debe tener la suficiente consistencia como para dar un buen resultado ante la introducción de datos diferentes. Para ello, el *data set* se divide en dos subconjuntos de datos: los datos de entrenamiento (*training data*), que corresponden aproximadamente al 80% de la data set y los datos de test (*test data*), que

corresponden al 20% restante y se emplearán para medir la calidad del modelo tras el entrenamiento (Chollet, 2017)

Una vez se tienen los datos se necesita establecer una hipótesis, es decir, encontrar una ecuación que se aproxime lo mejor posible al comportamiento real del fenómeno que se está modelizando. Esta ecuación es la que relaciona los datos de entrada y los parámetros del modelo con la salida. Aquello que no se mide no se puede mejorar, así que el siguiente paso consiste en encontrar el error en la predicción y tratar de minimizarlo (Belda, 2016)

3.3.2 El error y los problemas de ajuste

Lo principal que es de destacar del Machine Learning es la precisión y la capacidad de generalizar un modelo, estos dos aspectos son esenciales a la hora de realizar un modelado en *machine learning*, pero es imposible conseguir un modelo esté libre de errores. Comprender las principales fuentes del error ayuda a prevenir los problemas más comunes, como ser: el sobreajuste y el subajuste.

Los errores principales en la predicción de un modelo y que están asociados al algoritmo empleado son la varianza y el sesgo (*bias*). Existe un tercer tipo de error asociado a la cantidad de ruido de los datos de entrada, sobre el cual no se puede actuar porque es irreducible e independiente de lo bueno que sea el modelo (González, 2018)

El error de varianza está relacionado con el grado en el que la función objetivo cambia según los datos de entrenamiento proporcionados. Existen algoritmos que se ven muy influenciados por pequeñas variaciones en los datos de entrada, mientras que otros son más consistentes y absorben mejor estos cambios (González, 2018)

El subajuste (*underfitting*) se refiere a un modelo con un nivel de complejidad muy bajo que no tiene la precisión suficiente como para alcanzar un ajuste adecuado debido a

su alto sesgo. Puede ocurrir cuando el conjunto de datos de entrenamiento no es suficiente, o cuando se utiliza un modelo lineal para ajustar datos no lineales. Por otra parte, el sobreajuste (*overfitting*) se produce cuando el nivel de complejidad es elevado y, por lo tanto, el modelo no tiene la capacidad de generalizar su comportamiento ante diferentes datos de entrada. Sucede cuando el modelo recoge el ruido de los datos de entrenamiento y, en consecuencia, aumenta mucho su varianza (Belda, 2016)

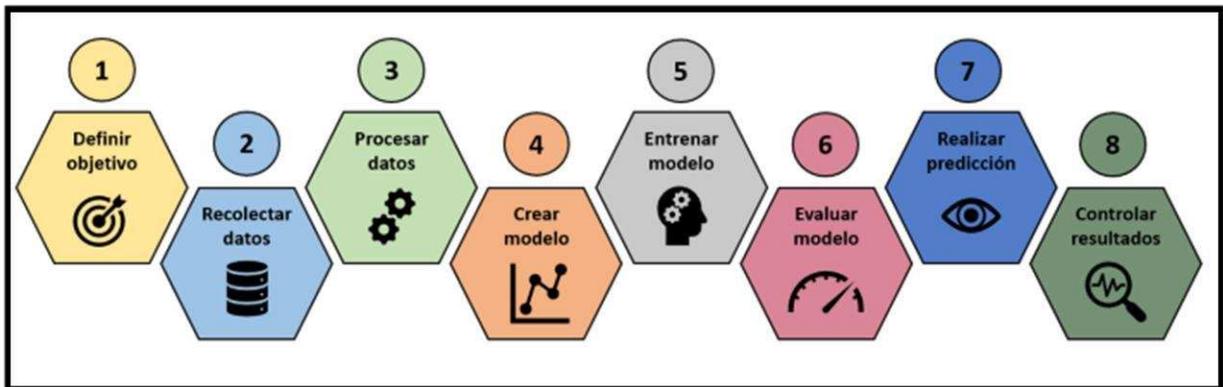
El problema más común es el del sobreajuste (*overfitting*), para el cual existen dos tipos de soluciones. La primera consiste en reducir el número de variables independientes (*features*), ya sea manualmente mediante la observación de aquellas variables que podrían desecharse, o bien a través de métodos que realizan esta tarea automáticamente. Sin embargo, se corre el riesgo de perder información realmente útil para el comportamiento del modelo. Por eso, la segunda opción es la regularización, gracias a la cual se mantiene el número de variables a costa de reducir el valor de los parámetros que afectan a las variables.

3.3.3 Etapas de un proyecto de Machine Learning

Bajo algunos conceptos básicos presentados en puntos anteriores, el machine learning dispone de un procedimiento para dar solución a problemas reales. Es de recalcar que no se centra únicamente en elegir un modelo y entrenarlo, sino que, como todo proyecto, cuenta con una serie de etapas o pasos a seguir para aumentar las probabilidades de éxito.

La figura 3.3 es una representación de los procedimientos seguidos en un proyecto empleando *machine learning*.

Figura 3. 2: Etapas genéricas para llevar a cabo un proyecto de



Fuente: Hozz, *Machine Learning For Beginners*, Mc Graw Hill, 2015

- **Primera etapa.** Consiste en entender el problema que se quiere resolver, ya que gran parte de las decisiones tomadas a lo largo del proyecto dependerán de lo bien que se haya comprendido el contexto (Sanchez, 2018)

Para ello es necesario definir unos objetivos claros, específicos, medibles y alcanzables en un periodo determinado de tiempo. Es una fase tediosa en la que se requiere mucha información por parte de expertos en el sector sobre el que se va a trabajar (Martinez, 2018)

- **Segunda etapa.** Se define la cantidad y el tipo de datos necesarios, así como el origen de dichos datos. La calidad de los datos que alimentan la máquina tiene un impacto directo en el funcionamiento del modelo (Bagnato, 2018)

En algunos casos, no se dispone de todos los datos necesarios para resolver el problema, por lo que se compran a entidades externas. Aun así, en otros muchos casos no se puede acceder a los datos deseados porque ni siquiera existen (Velogig, 2018)

- **Tercera etapa.** Es el tratamiento de los datos una vez recolectados. El objetivo principal de esta etapa es visualizar y analizar cuáles son las variables que mejor representan aquello que se quiere predecir (Sanchez, 2018)

- **Cuarta etapa.** Define por completo el modelo que mejor se ajuste al problema: regresión lineal, árbol de decisiones, red neuronal, k-vecinos más cercanos, entre otros.
- **Quinta etapa.** Se dedica al entrenamiento del modelo a partir de los datos de entrenamiento. Los parámetros se ajustan automáticamente por el algoritmo seleccionado a medida que se entrena el modelo (Bagnato, 2018)
- **Sexta etapa.** Se verifica la precisión del modelo mediante la introducción de los datos de test, que son datos que la máquina aún no conoce. Un 50% de precisión es insuficiente para validar un modelo, pues indica que la mitad de las veces fallará. En cambio, alcanzar un 90% de precisión proporciona una confianza suficiente. También se evalúan los errores que hacen que el modelo no generalice bien con el fin de elegir la solución más conveniente: adquirir más datos, usar un modelo más simple, usar uno más complejo, comprender mejor el problema, etc. A esta etapa también se la conoce como *Parameter Tuning* (configuración de parámetros), pues consiste en ajustar los parámetros del modelo para mejorar los resultados obtenidos (Bagnato, 2018)
- **Séptima etapa.** Se realiza la predicción aplicando los modelos predictivos que existen dentro del sistema de machine learning, los cuales muestran gráficas de las variables en estudio, representando sus variaciones máximas y mínimas y su comportamiento en el futuro.
- **Octava etapa.** Pone fin al proceso con la monitorización de los resultados. Es necesario asegurar que el modelo aporta un alto valor predictivo y, lo más importante, que cumple con los objetivos marcados en la primera etapa (Sánchez, 2019).

3.4 ALGORITMOS DE MACHINE LEARNING

Los algoritmos, esencialmente son motores que impulsan el *Machine Learning* y los principales son:

- Aprendizaje supervisado.
- Aprendizaje no supervisado.
- Aprendizaje reforzado.

3.4.1 Aprendizaje supervisado

En el aprendizaje supervisado, el agente observa pares de datos de entrada y salida a modo de ejemplo para aprender una función que modele la salida según la entrada (Russell & Norvig, 2010).

Por lo tanto, en los datos utilizados para construir el modelo se encuentra la información que se desea predecir. Existen dos tipos de problemas en el aprendizaje supervisado: los problemas de regresión y los problemas de clasificación, fundamentalmente, un modelo de regresión predice una cantidad continua mientras que un modelo de clasificación predice una etiqueta (Management Solutions España, 2018).

3.4.2 Aprendizaje No supervisado

El aprendizaje no supervisado divide en segmentos los datos con características similares llamados clusters. A los datos se les asignan distintos parámetros para después poder clasificarlos, en este punto se puede decir que se vuelve una especie de aprendizaje supervisado. Las aplicaciones de este tipo de algoritmos también son muy variadas, pero es menos utilizado porque la complejidad de estos algoritmos es mayor a la de los algoritmos de aprendizaje supervisado.

(Management Solutions España, 2018).

Una de las principales aplicaciones del aprendizaje no supervisado es el de identificar grupos de amigos cercanos en redes sociales, Twitter, Instagram y Facebook tienen una cosa en común: la gran cantidad de datos no etiquetados que generan sus millones de usuarios. Entender el significado de todos estos datos no es una tarea fácil, estas grandes empresas utilizan algoritmos capaces de encontrar patrones y agrupar todos estos datos.

3.4.3 Aprendizaje Forzado

Los algoritmos de aprendizaje reforzado son algoritmos que reciben retroalimentación a partir del análisis de los datos que realiza, así los analistas de datos pueden guiarlo y asegurarse de obtener mejores resultados. Puede sonar parecido al aprendizaje supervisado porque al igual que éste tiene intervención humana, la diferencia radica en que este tipo de algoritmos no está entrenado con un conjunto de datos de muestra. El sistema aprende a base de prueba y error, en cierto punto se puede decir que es una combinación del aprendizaje supervisado y el no supervisado, porque tiene intervención humana, pero solo al final del proceso, durante el proceso el sistema realiza todo sin alguna intervención humana. (Russell & Norvig, 2010).

3.5 MÉTODOS DEL MACHINE LEARNING EN PERFORACIÓN

3.5.1 Método de Machine Learning vectorial para predecir la NPT en la perforación

Una de las herramientas matemáticas para hacer una predicción razonable durante las operaciones de perforación es la implementación de herramientas de aprendizaje automático. Se basa en el análisis de datos de un conjunto de datos recopilados debido a la amplia gama de herramientas de aprendizaje automático utilizadas en las operaciones de perforación y la precisión de su predicción para aplicaciones de campo.

Nos permitirá definir un patrón de perforación adecuado basado en el análisis de regresión. Suykens y De Moor (1990) desarrollaron el algoritmo Support Vector Machine (SVM) para LSSVM (Least Square Support Vector Machine). Este nuevo algoritmo puede proporcionar soluciones analíticas convenientes y más rápidas que el algoritmo SVM. (Dorado & Velázquez, 2020)

A continuación, el algoritmo LSSVM se calcula analíticamente utilizando un algoritmo genético (GA) en el software MATLAB. El proceso del algoritmo LSSVM-GA para resolver el problema propuesto se define de la siguiente manera:

Para funcionalizar y optimizar el enunciado del problema, se define un método SRM (Sachsenring Rennstrecken Management) para resolver la función R. La fórmula de cálculo es:

$$R(\omega, e, b) = \frac{\omega^2 + C \sum_{i=1}^n e_k^2}{2} \quad (3.1)$$

donde ω es el factor de peso, b es el término de sesgo, C es la constante de regularización y e_k es la función de error de entrenamiento.

Entonces, la función de salida se define como:

$$f(x) = \sum_{i=1}^N a_i f(x, x_i) + b \quad (3.2)$$

Donde a y b son la función de ruta que se obtiene de la siguiente manera:

$$a = \left(\delta + \frac{1}{\gamma} I_n \right)^{-1} (y - I_n b) \quad (3.3)$$

$$b = \frac{I_n^T \left(\delta + \frac{1}{\gamma} I_n \right)^{-1} y}{I_n^T \left(\delta + \frac{1}{\gamma} I_n \right)^{-1} + I_n} \quad (3.4)$$

Finalmente, MSE (error cuadrado medio) se calcula como

$$MSE = \frac{\sum_{i=1}^n (\rho_{est} - \rho_{exp})^2}{n_s} \quad (3.5)$$

Donde:

I_n : Matriz de ruta

I_n^T : Matriz de ruta transpuesta

δ, γ : Factores de corrección

n_s : Número total de iteraciones

a, b : Funciones de ruta

$f(x, x_i)$: Función b variable

ρ : Densidad del fluido de perforación estimada y experimental.

En este caso, el valor estimado es el valor de densidad del fluido de perforación del pozo en el sub andino, y el valor experimental son los datos obtenidos del fluido de perforación de los pozos anteriores, es decir, el valor de error densidad del fluido de perforación.

3.5.2 ANFIS (Sistema de Inferencia Neuro-Difusa Adaptativa)

Una red ANFIS puede entenderse como una red neuronal con reglas basadas en datos imprecisos, que propone resultados para una determinada combinación de información de entrada y cuyos parámetros se obtienen mediante entrenamiento. Estos sistemas son ideales para interpretar sistemas de entrada y salida no lineales que no están claros o están definidos de forma imprecisa (Goharian et al., 2017).

La regla que caracteriza a los modelos difusos de Sugeno tiene la forma Si la entrada 1 = x y la entrada 2 = y, entonces la salida es $z = ax + by + c$. La contribución de cada regla (z_i) en términos de salida del sistema es ponderada por el peso (w_i) de la regla y el resultado final del sistema es el resultado ponderado de las salidas de cada una de las N reglas:

$$S_{ANFIS} = \frac{\sum_{i=1}^n \rho_{est} * z_i}{\sum_{i=1}^n \rho_{est}} \quad (3.6)$$

3.5.3 PSO-ANFIS (Optimización de Enjambre de Partículas-Sistema de Inferencia Neuro-Difusa Adaptativa)

(PSO) es un algoritmo metaheurístico de población que se ha aplicado con éxito para resolver problemas de optimización, inspirado en el comportamiento social del vuelo de la bandada o el movimiento de los peces. El algoritmo PSO fue desarrollado por Kennedy y Eberhart con base en un enfoque de metáfora social y se basa en factores que influyen en la toma de decisiones de partículas que forman parte de un grupo de partículas similares (Mora & Flores, 2013).

La decisión de cada partícula se toma en términos de un componente social y un componente individual, por lo que se determina el movimiento de esta partícula para alcanzar una nueva posición en el espacio de soluciones. Las metaheurísticas intentan simular este comportamiento para resolver problemas de optimización.

Se debe utilizar un modelo de redes neuronales basado en PSO o Enjambre de partículas para predecir la probabilidad de que se presente un NPT. La optimización de enjambre de partículas (PSO) es el algoritmo propuesto para realizar el aprendizaje automático. Este modelo depende de las siguientes relaciones:

$$V_{id} = w \times v_{id} + (c_1 \times r_1) \times (p_{id} - x_{id}) + (c_2 \times r_2) \times (p_{gd} - x_{id}) \quad (3.7)$$

$$X_{id} = x_{id} + v_{id} \quad (3.8)$$

Donde:

c_1 y c_2 son constantes positivas

r_1 y r_2 son funciones aleatorias en el rango $[0,1]$

$x_i = (x_{i1}, x_{i2}, \dots, x_{id})$ representa la i -ésima partícula

$p_i = (p_{i1}, p_{i2}, \dots, p_{id})$ representa la mejor posición anterior de la i -ésima partícula (la posición con el valor de fitness más alto)

g representa el índice de la mejor partícula de la población

$v = (v_{i1}, v_{i2}, \dots, v_{id})$ es el valor de dispersión (Amin & Rodin, 1998)

3.5.4 LSSVM-GA (Máquina de Vector de Soporte de Mínimo Cuadrado)

Las SVM pueden ser equivalentes al análisis estadístico de regresión lineal o no lineal de uso común, como la regresión múltiple, pero son más sólidas y la calidad de las SVM está determinada por la capacidad de entrenamiento y generalización (Cristianini et al., 2000).

3.5.5 RBF (Función de Base Radial)

Una función de base radial (RBF) define una hipersfera o hiperelipse que divide el espacio de entrada. Cada RBF construye una aproximación no lineal local dentro de una región del espacio de entrada. RBF construye aproximaciones que son combinaciones lineales de múltiples funciones locales no lineales (Serrano, 2010)

CAPÍTULO 4: DESCRIPCIÓN DEL BLOQUE SUB ANDINO

4.1 CORRELACIÓN HIDROCARBURO – ROCA MADRE

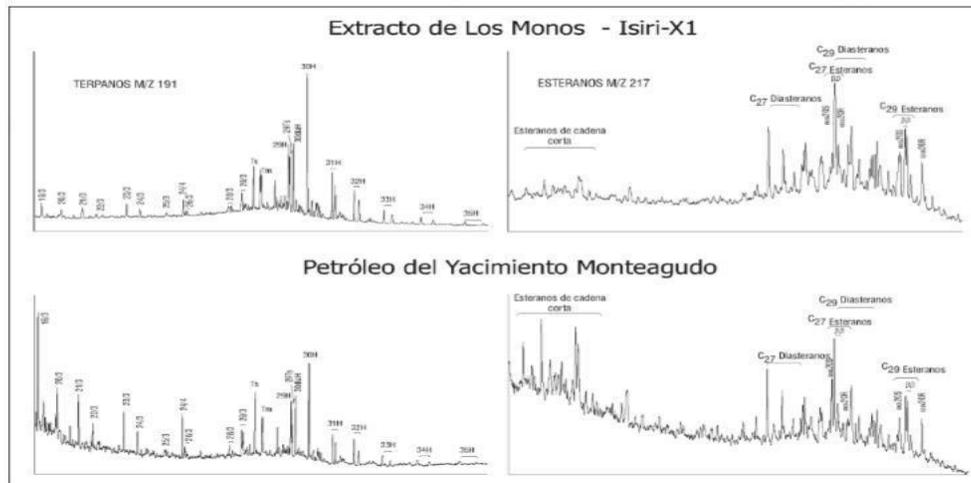
Los hidrocarburos dominantes en la Cuenca de Tarija son petróleo liviano, condensado y gas (Illich et al., 1981). Este hecho dificulta la evaluación de patrones definidos de correlación roca madre – petróleo y petróleo – petróleo. A pesar de ello, se han realizado numerosos estudios para comprobar las relaciones genéticas (Cruz, Mombrú, & Cangini, 2003).

En el área de Santa Cruz, un petróleo del yacimiento Río Grande (reservorio Carbónico) se considera originado en etapa de pico máximo de generación, a un nivel de madurez superior al de la sección Eifeliano y comparable al de la sección Lochkoviano del pozo DRD-X1001. En tanto, una muestra de condensado del reservorio Huamampampa en el pozo TCB-X1001 (Tacobo), aunque con pérdida importante de componentes livianos, registró una madurez estimada de 1.2- 1.3%Ro (análoga a la de condensados de reservorios del Carbónico de Río Seco y Terciario de Tajibos, Figura 2). Se lo interpreta como originado sobre el final de la etapa de generación de gases húmedos, fase de madurez propia del Lochkoviano en DRD-X1001 y comparable a la atribuida a la sección Lochkoviano de TCBX1001, de acuerdo con el perfil de madurez térmica proyectado a partir de medidas de Ro. En la misma zona, pero en la región de influencia del Alto de Izozog, un petróleo del yacimiento Tita (reservorio Carbónico) sugiere una madurez térmica de 0.9% RVE, similar a la que presenta la sección Eifeliano del pozo UTZ-X1. De acuerdo con los fingerprints de biomarcadores, el petróleo de Tita muestra consanguinidad con el petróleo del yacimiento Monteagudo y, consecuentemente, se interpreta como generado por la sección Eifeliano – Los Monos (Cruz, Mombrú, & Cangini, 2003).

Las acumulaciones de gas se atribuyen a generaciones múltiples. Los datos isotópicos, orga- nizados por edad de reservorio y ubicación geográfica (Figura 4.1),

señalan variaciones importantes en la madurez térmica permitiendo la postulación de distintas “cocinas” de una misma roca madre y/o cogeneración.

Figura 4. 1: Correlación de petróleo



Fuente: Cruz, *Hábitat de hidrocarburos en el Pie de Sierra de la Faja Corrida.*, 2003

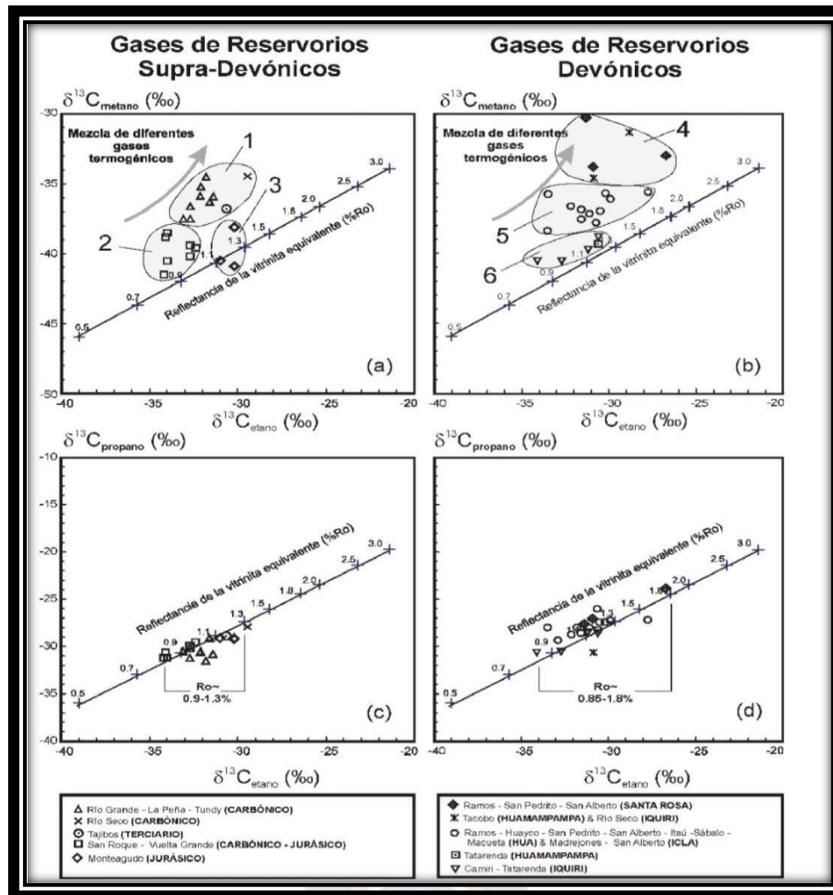
Se observa la roca madre de un petróleo del Yacimiento Monteagudo con un extracto de la Sección Eifeliano (Fm. Los Monos) del pozo Isiri-X1 en la Faja Plegada y Corrida del Subandino Sur.

Los gases de reservorios supra-devónicos (Figura 4.2) se dividen en tres grupos:

- (1) Muestras de Río Grande-La Peña-Tundy junto con muestras de Río Seco y Tajibos del área de Santa Cruz;
- (2) Muestras de San Roque y Vuelta Grande en el área de Pilcomayo
- (3) Muestras de Monteagudo en la Faja Corrida del Subandino Sur. Los gases del conjunto (1) muestran según sus datos isotópicos de metano mayor madurez respecto de los otros gases y, además apartamiento significativo de la línea cogenética metano-etano.

Los gases de los reservorios devónicos muestran ciertas peculiaridades en su distribución. En particular, la fracción isotópica del metano (Figura 8b) del gas de Santa Rosa en los yacimientos Ramos y San Alberto exhiben una identidad de ^{13}C mucho menos negativa si se la compara con la del gas de Huamampampa.

Figura 4. 2: Evaluaciones de la madurez térmica de las muestras de gas



Fuente: Cruz, Hábitat de hidrocarburos en el Pie de Sierra de la Faja Corrida., 2003

El gas de Tacobo no cuenta con dato isotópico de propano (Whiticar, 1994).

Esto se atribuye a un probable aporte de gas seco desde una roca generadora muy madura (presumiblemente una sección silúrica o devónica basal), situación que naturalmente es mucho más probable que el aporte de una roca madre terrígena no documentada (querógeno Tipo III / carbón). La existencia de un gas de mayor madurez

en reservorios de Santa Rosa también se produce en San Pedrito (Figura 10 en Cruz et al., 2002). Una situación de alta madurez

4.2 RESERVIOS Y TRAMPAS

La totalidad de la columna estratigráfica presenta niveles reservorio en la Cuenca de Tarija, desde el Devónico Inferior hasta las secuencias basales del Terciario Orogénico (Cruz et al., 2003). En sentido amplio, los reservorios se pueden agrupar en devónicos y supra-devónicos, consideración que sirve de base a Starck (1999) para su propuesta de sistemas petroleros.

Las dos regiones de la cuenca que tienen yacimientos de hidrocarburos son el Subandino Sur y el Pie de Monte (Figura 2), donde las trampas son estructurales de manera dominante. Hasta el momento no existe registro de entrapamiento puramente estratigráfico, del mismo modo que la Llanura Chaqueña no presenta yacimientos de envergadura. Algunas acumulaciones en el Terciario en el Pie de Monte, donde los reservorios son areniscas fluviales efímeras de marcada lenticularidad, posiblemente tengan una fuerte influencia estratigráfica en el entrapamiento.

En los puntos siguientes se describirán las características estructurales de los campos más importantes o representativos de las regiones productivas que componen la Cuenca de Tarija.

4.2.1 Porosidad del reservorio

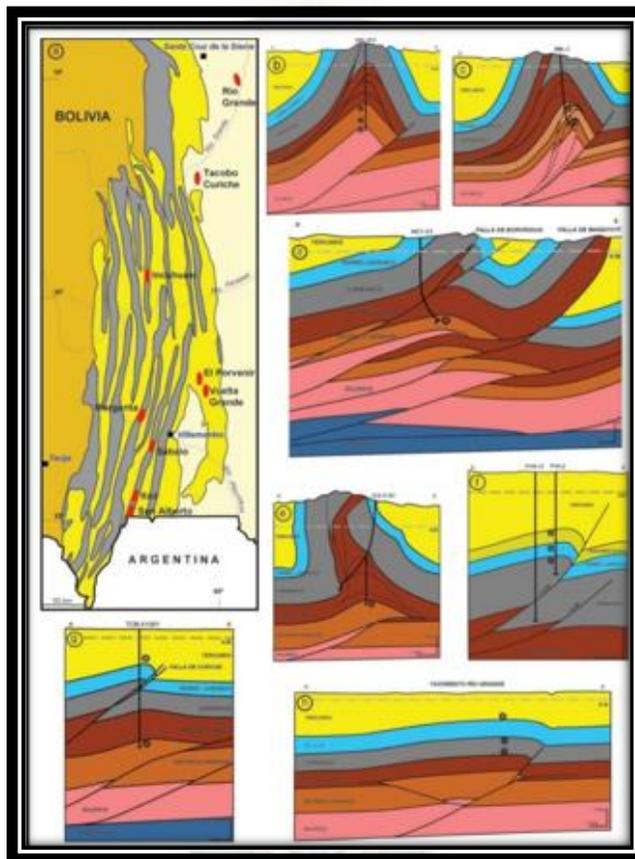
Las areniscas nos interesan porque tienen porosidad, que es el porcentaje de espacios existentes entre los granos de una roca, y que están ocupados por hidrocarburos o agua. Gracias a esta propiedad, estas rocas pueden almacenar grandes volúmenes de hidrocarburos, razón por la cual se las denomina rocas reservorio o rocas almacén.

También existe porosidad de fractura (secundaria) en rocas muy compactadas y cementadas como sucede con los reservorios del Devónico (Fm Huamampampa).

4.2.2 Subandino Sur

A continuación, se aprecia el Sub Andino sur:

Figura 4. 3: Mapa estructural del subandino



Fuente: Energy Press, Informe litológico, 2012

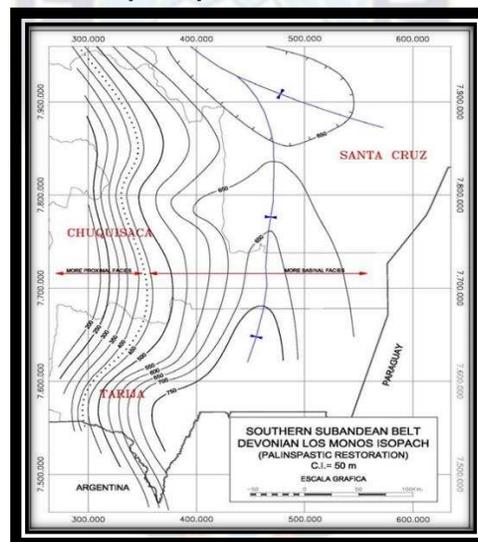
Las trampas de esta región corresponden a estructuras anticlinales bien preservadas, con cierre en cuatro sentidos y cuyas dimensiones es del orden de decenas de kilómetros. Han sido analizadas profundamente por Kozlowski et al (2005) en el sector argentino y, si bien se ha descrito al pliegue subandino idealizado, existen algunas diferencias en la geometría de las trampas en el sector boliviano.

El Subandino Sur presenta espesores superiores a los 10.000 metros de rocas sedimentarias cuyas edades comprenden del Silúrico al reciente. Intercalaciones de areniscas y lutitas de plataforma marina del silúrico al devónico están sobrecubiertas por secuencias glaciofluviales a marino-somero del Carbonífero-pérmico-triásico y esta a su vez por sedimentos fluvio-eólicos del Cretácico progradando a depósitos de cuenca de foreland durante el terciario. Toda esta secuencia fue deformada y plegada durante la orogénesis andina del mioceno tardío.

4.2.2.1 **Mapa isópaco de la Formación Los Monos**

Las rocas madre principales de hidrocarburos en el área son las lutitas de las formaciones Kirusillas y Los Monos.

Figura 4. 4: Mapa Isópaco de la formación los Monos



Fuente: Cruz, *Hábitat de hidrocarburos en el Pie de Sierra de la Faja Corrida.*, 2003

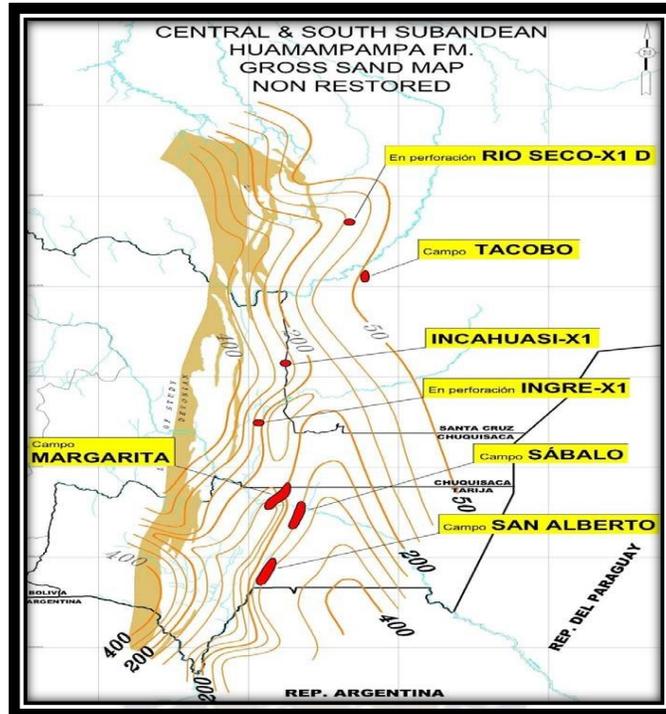
Se encuentran ampliamente distribuidas en todo el subandino, como ejemplo podemos observar en el mapa de espesores (isópaco) de la Formación Los Monos.

4.2.2.2 **Mapa isópaco del reservorio Huamampampa**

Desde el punto de vista de producción de gas y condensado, los reservorios principales en el Subandino sur son las formaciones Santa Rosa, Icla y

Huamampampa, siendo esta última la mayor productora en los megacampos San Alberto, Sábalo y Margarita.

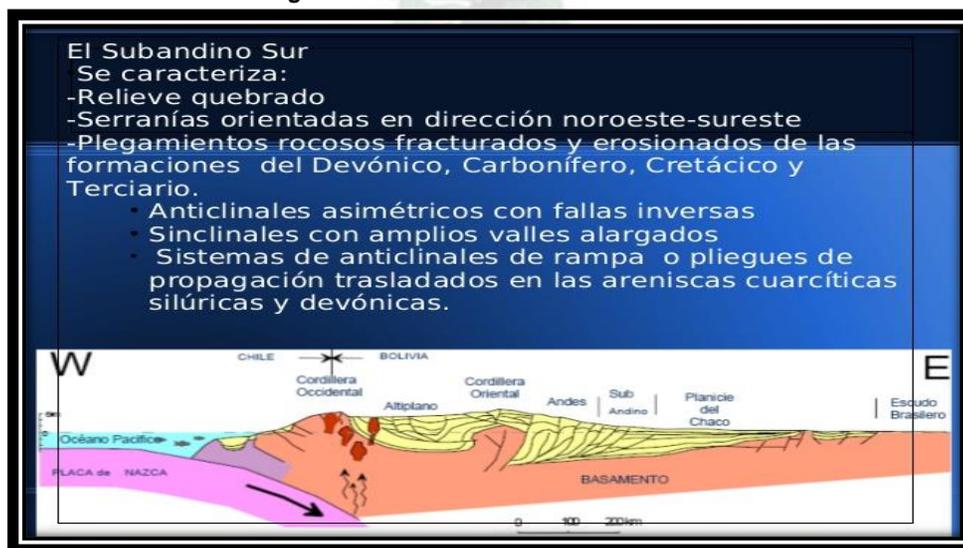
Figura 4. 5: Mapa isópaco del reservorio Huamampampa



Fuente: Cruz, Hábitat de hidrocarburos en el Pie de Sierra de la Faja Corrida., 2003

Se resume las características en la siguiente gráfica:

Figura 4. 6: Características del subandino



Fuente: Yacimientos Petrolíferos Fiscales Bolivianos, Informe del Sub Andino Sur., 2014

Muy difícil de describir debido a los ambientes deposicionales.

Abruptos cambios de facies en cortas distancias, las cuales han sido documentadas por afloramientos, pozos y la sísmica 2D –3D.

Litología: conglomerados, areniscas, diamictitas, lutitas, arcillitas.

Caracterización

- Altos buzamientos
- Sistema de esfuerzo tipo strike slip
- Abrasividad
- Alta resistencia a la compresión
- Bajos Gradientes de fractura
- Problemas potenciales:

Estabilidad de pozo

- Perdidas
- Baja ROP
- Desviación
- Break outs
- Diámetros de perforación 26" y 17 ½"
- Alta sollicitación de H



CAPÍTULO 5: APLICACIÓN PRÁCTICA

4.3 DATOS DE PRESIÓN PERFORACIÓN PLANIFICADOS PARA EL BLOQUE SUB ANDINO

Los datos de profundidad vs. Tiempo de perforación del primer y segundo pozo son los siguientes:

Tabla 5. 1: Datos del perfil del pozo HYC X1

Prof	P 10	P 50	P 90	Actual
0	0	0	0	0
-200	5	10	12	15
-600	10	15	20	20
-1600	32	42	60	60
-2100	50	60	100	90
-3400	110	160	210	---
-4000	140	190	280	---
-4700	170	215	350	---
-5000	180	235	380	---

Fuente: YPF Repsol, 2021

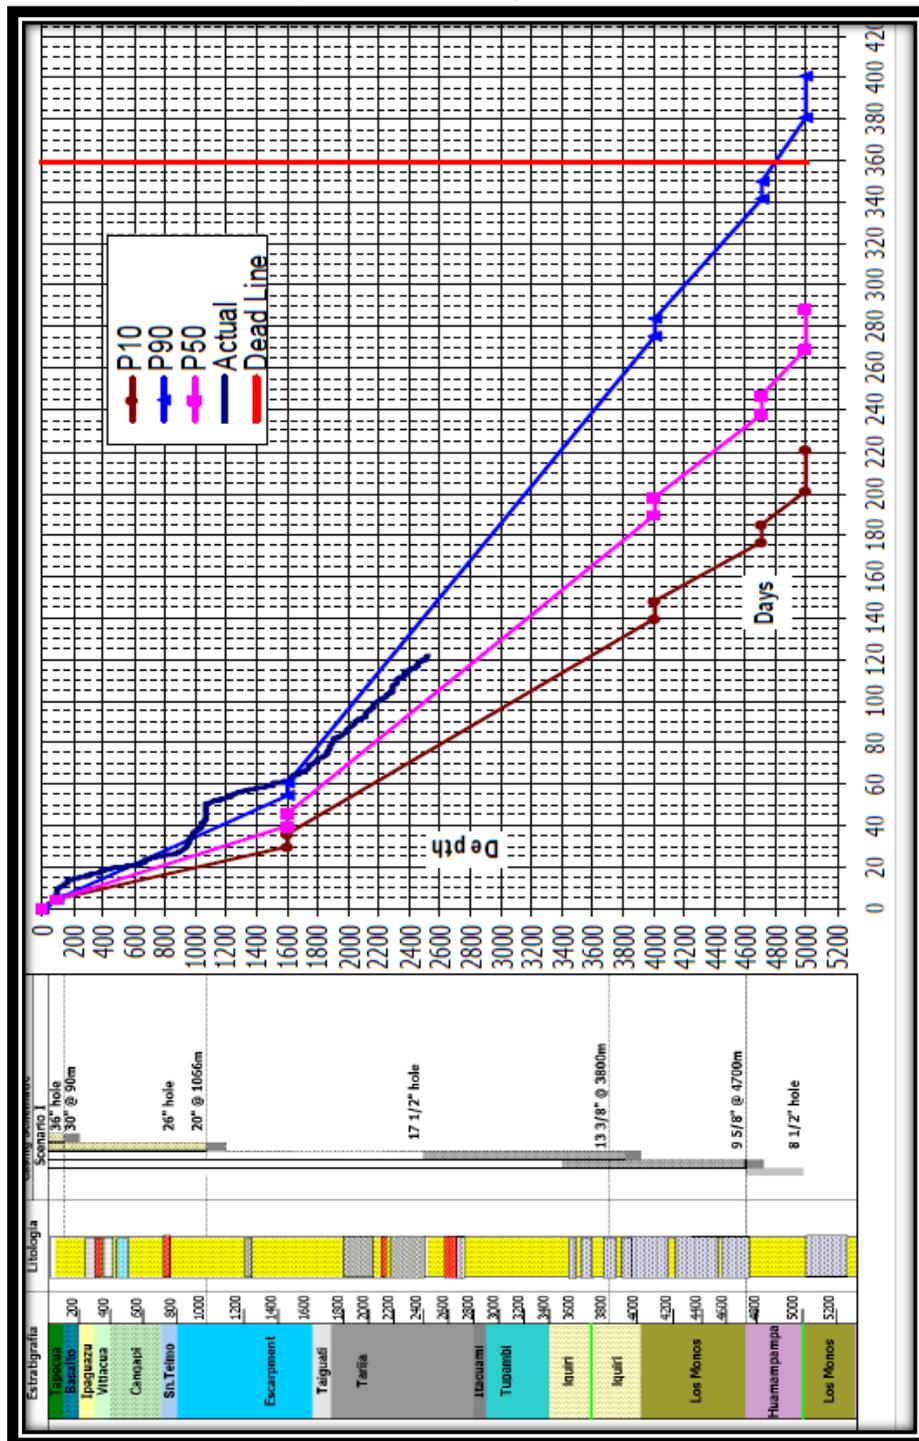
Tabla 5. 2: Datos del perfil del pozo HCW X2

Prof	P 10	P 50	P 90	Actual
0	0	0	0	0
-700	25	35	52	40
-2100	80	110	145	132
-3400	140	190	275	160
-4400	175	235	340	240
-4700	185	250	350	255
-5100	---	---	---	290

Fuente: YPF Repsol, 2021

Las gráficas de dónde se obtuvieron los datos:

Figura 5. 1: Perfil del pozo HYC X1



Fuente: Yacimientos Petrolíferos Bolivianos. Informe litológico del Bloque Sub Andino Sur, 2019

4.4 MODELOS PREDICTIVOS DE MACHINE LEARNING PARA EL CONTROL DE TIEMPOS NO PRODUCTIVOS EN LA PERFORACIÓN

4.4.1 Desarrollo del modelo en Machine learning

A continuación, se desarrolla la simulación en Matlab para realizar el análisis mediante redes neuronales y encontrar los modelos óptimos en función de una predicción de Tiempos no productivos.

Se escogen los diferentes modelos ya incorporados en el Software Matlab, las que más ofrecen una variedad dentro de su sistema ya programados y listos para utilizar.

Para poder hacer funcionar la simulación se deben seguir los siguientes pasos:

1. Abrir el programa de MATLAB.
2. Ejecutar el código “nnstar” programado en una subcarpeta.
3. Tratar los datos iniciales obtenidos de la densidad, de la variación de presión y otros que sean necesarios para el análisis.
4. Presionar los comandos ctrl + enter para hacer correr cada modelo dentro del programa.
5. Una vez ejecutado el programa, se obtendrán las imágenes de los datos simulados y las relaciones estadísticas.

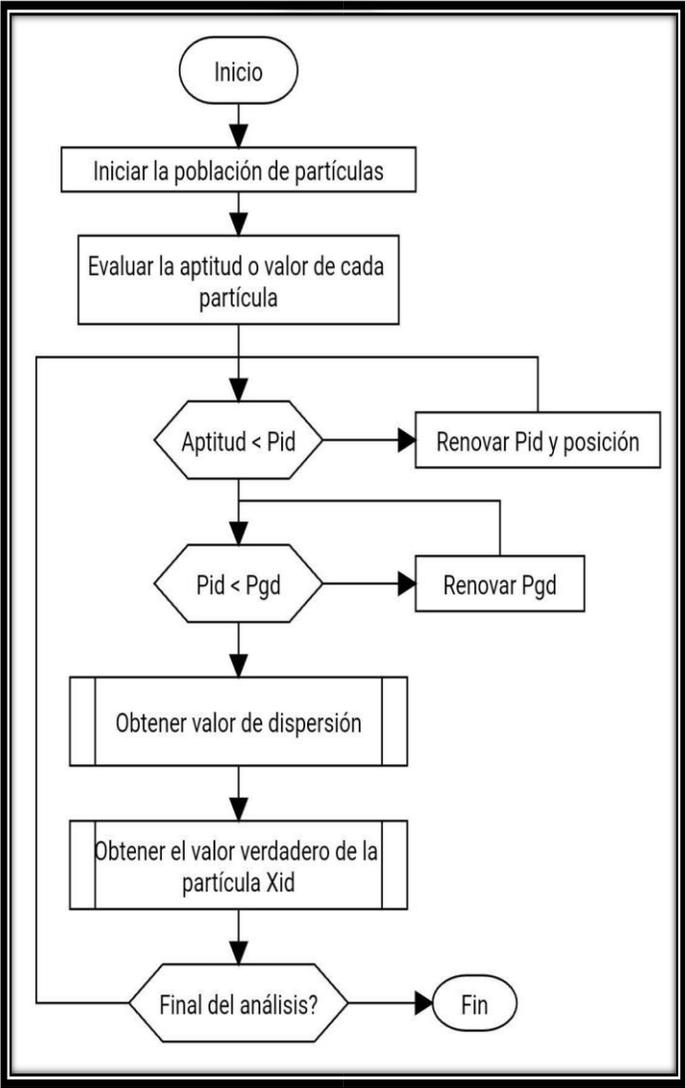
Para realizar correctamente la simulación se debe definir la población de partículas de datos a partir de varios pozos dentro de la zona de estudio. Después se procede a evaluar el valor de cada dato y registrarlo en la base del Machine learning.

Si el valor esperado es menor se procede a iterar nuevamente hasta obtener un valor acertado predictivo. Luego se debe evaluar los valores de presión densidad velocidad correctos para evitar tiempos no productivos.

De esa forma se realiza la simulación para cada modelo propuesto que se programa con la app de manera automática. Ya que ofrece un menú para los anteriores modelos presentados. Se debe obtener posteriormente el grado de dispersión de los datos y comparar entre cada modelo el error. Finalmente se obtiene el valor verdadero.

El diagrama de flujo del algoritmo se muestra en la siguiente figura:

Figura 5. 3: Diagrama de flujo del algoritmo PSO



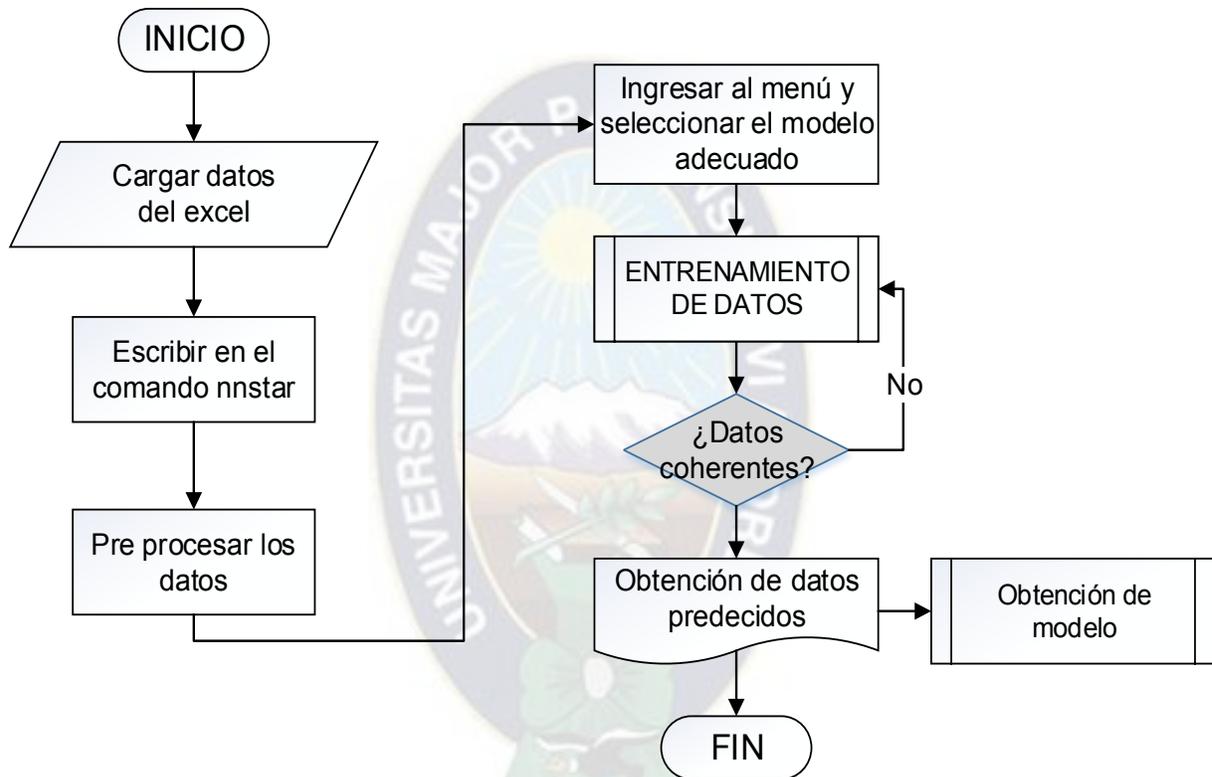
Fuente: Elaboración propia en base a Visio, 2023

Según el anterior diagrama, se ingresa la base de datos conocido como el inicio de población de partículas que se ingresa en Matlab. Seguidamente se devalúa la aptitud,

es decir los nuevos datos que promedia este programa. Los valores deben ser mayores, caso contrario se vuelve a ingresar nuevos datos supuestos, luego se obtiene el valor verdadero y se termina con la iteración.

Para el programa se tiene el siguiente diagrama de flujo:

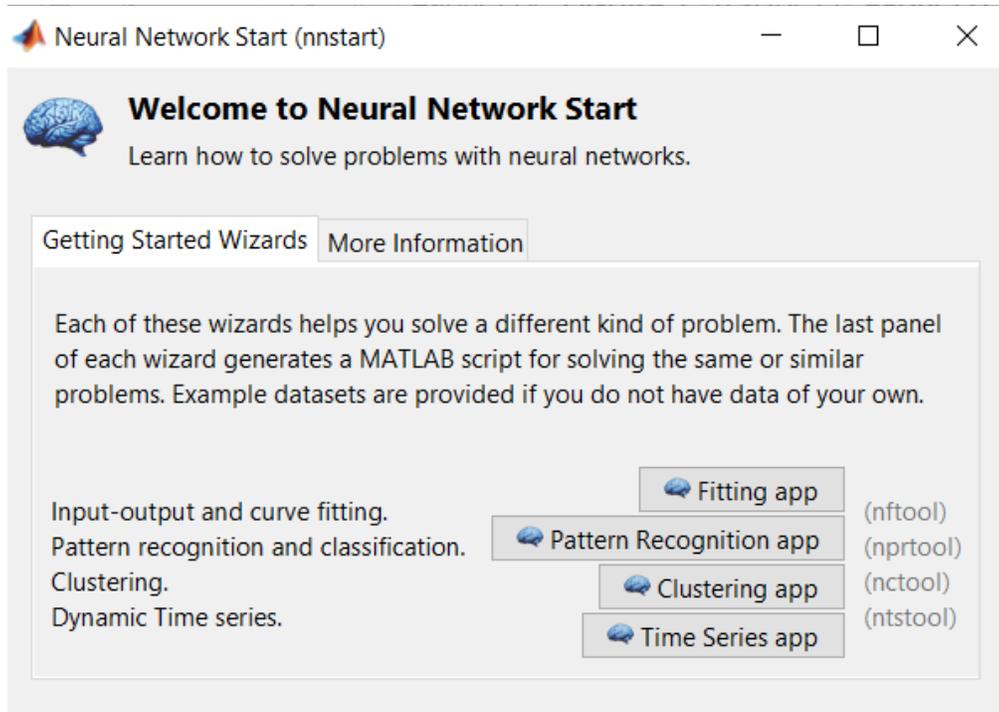
Figura 5. 4: Diagrama de flujo se la simulación en Matlab



Fuente: Elaboración propia en base a Visio, 2023

Entonces, primero que se realiza es ingresar los datos en el programa. Para ingresar a esta imagen se coloca el código en la barra del matlab nnstar y aparece automáticamente esta opción y se escoge la opción de partículas. Anexo se encuentran más imágenes de este programa. (Ver Fig 5.4)

Figura 5. 5: Presentación de bienvenida a Matlab



Fuente: Elaboración propia en base a MATLAB, 2023

En anexos se ve a detalle las características del programa de Machine Learning aplicado en Matlab y las regresiones obtenidas.

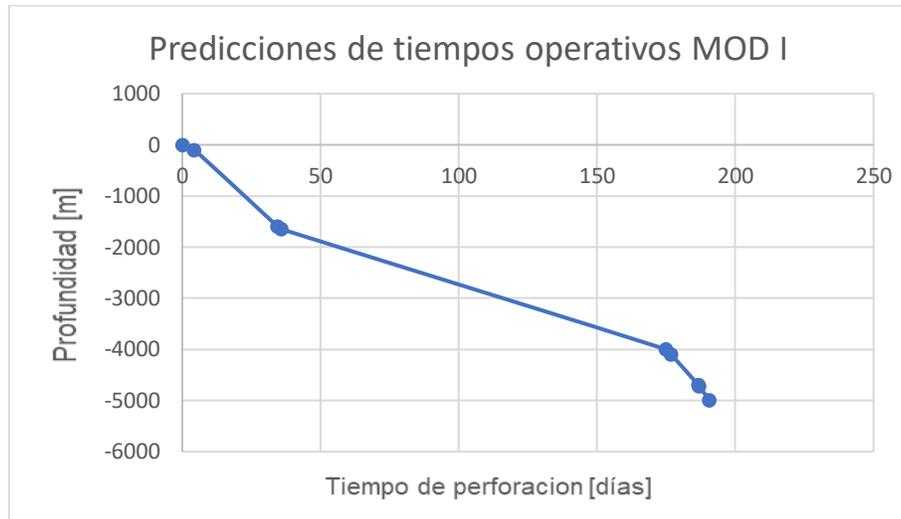
Repetir la simulación hasta que existen la congruencia entre los datos.

Para el modelo ANFIS

En el gráfico podemos observar las variaciones de las densidades de manera lineal, Eso quiere decir que hay una leve separación entre los valores de las densidades y con todos los datos simulados se logra obtener una relación de una recta. Según esta gráfica podemos observar que a mayor profundidad Se debe incrementar el valor de la densidad debido a que el pozo es de alta presión y alta temperatura.

A continuación, se presenta la gráfica de la presión predicha con el modelo ANFIS:

Figura 5. 6: Función del primer modelo

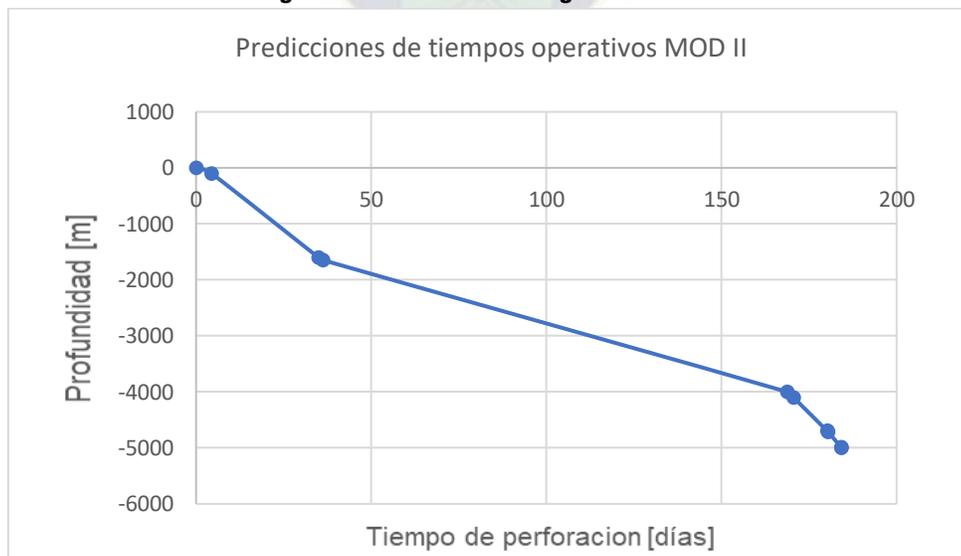


Fuente: Elaboración propia en base a datos calculados, 2023

Se puede demostrar que hay un cambio en el aspecto gráficos debido a la variación del algoritmo que ofrece el modelo ANFIS

Para el modelo PSO-ANFIS

Figura 5. 7: Función del segundo modelo



Fuente: Elaboración propia en base a datos calculados, 2023

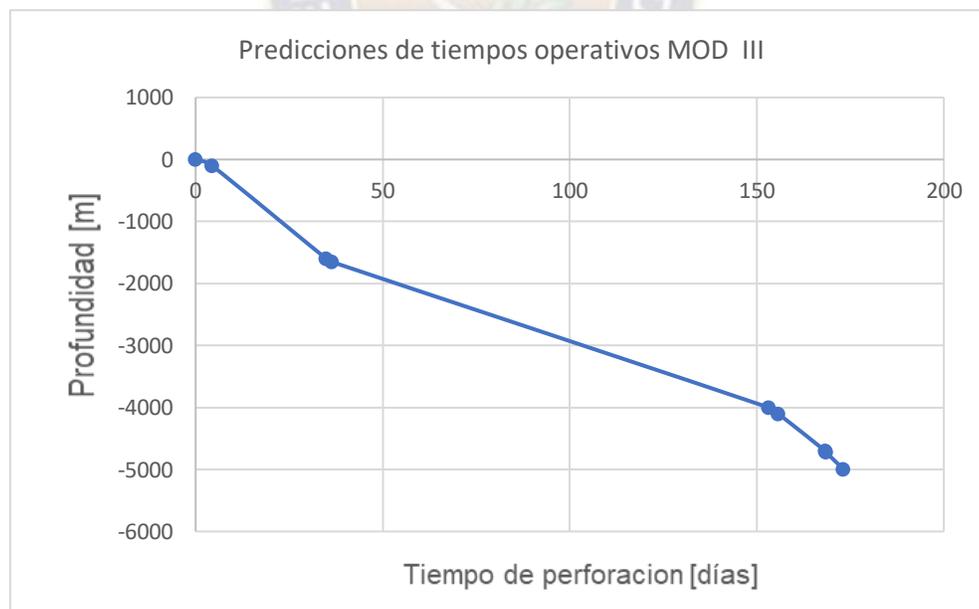
Con este modelo también podemos observar que existe una relación lineal entre el tiempo y la profundidad del pozo, donde indica claramente que a mayor profundidad se incrementa el tiempo de perforación.

En el anterior gráfico se puede ver el modelo de densidad del lodo que se obtuvo en función a la profundidad con el algoritmo PSO QNFIS donde se puede presenciar un cráter en los datos, esto quiere decir que hay una pequeña concavidad debido a la variación de datos en la simulación.

Para el modelo LSSVM-GA

Este modelo está agrupando los datos de los tres pozos y afirma que en cualquiera área que se perforé en este campo, se debe incrementar la presión del pozo para evitar cualquier problema de derrumbe.

Figura 5. 8: Función del tercer modelo



Fuente: Elaboración propia en base a datos calculados, 2023

El modelo LSSMV más conocido como el modelo levenberg que fue aplicado en la segunda guerra mundial para detectar datos, revela igual una pequeña concavidad en la curva donde se puede observar el comportamiento de la presión que indica que se

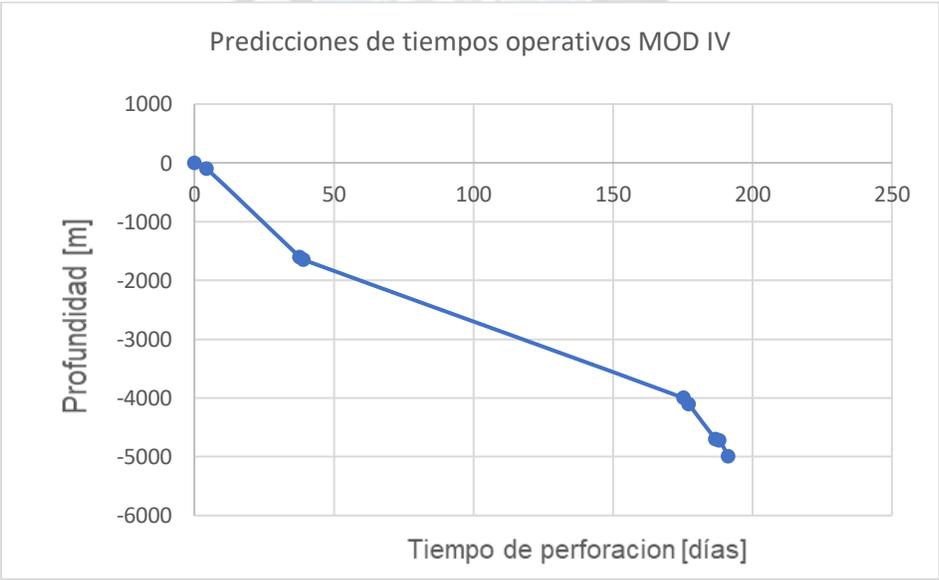
debe incrementar, después disminuir y otra vez continuar con el incremento de la densidad debido a las variaciones de presión debido a la estructura del pozo.

Para el modelo RBF

Este nos indica que existen zonas donde existe una alta variación de los datos debido al incremento de la profundidad, es decir que hay zonas donde se debe controlar los tiempos no productivos y de perforación, es un modelo que se asemeja bastante a la realidad ya que la presión del poro varía de distinta manera dentro del pozo y hace que se generen esas variaciones de presión.

Debido a la perfección en la regresión se presenta el siguiente modelo para obtener datos durante la perforación del pozo

Figura 5. 9: Función del cuarto modelo

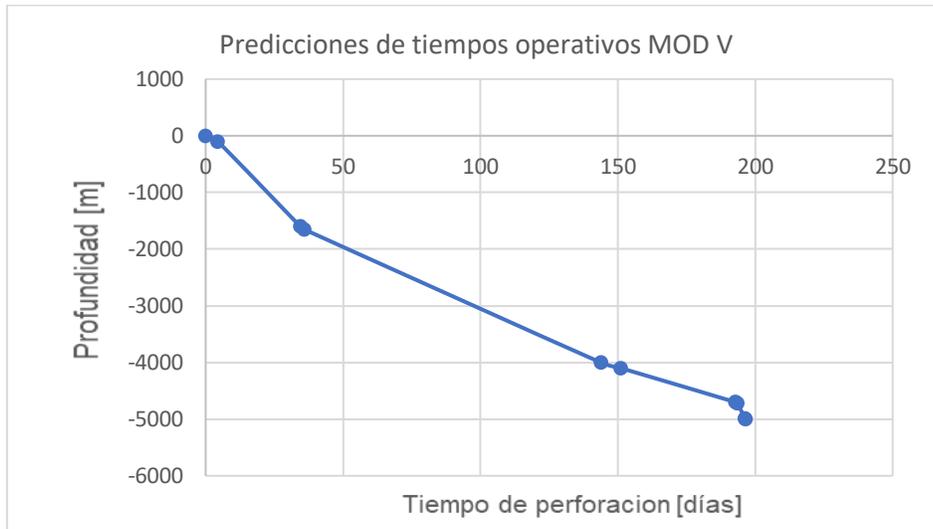


Fuente: Elaboración propia en base a datos calculados, 2023

Es el modelo más actualizado en la teoría de redes neuronales e inteligencia artificial, será el que se utilizará para presentar en la predicción de la variación de los tiempos de perforación debido a las presiones de fondo de pozo

De la misma forma se obtiene su siguiente función:

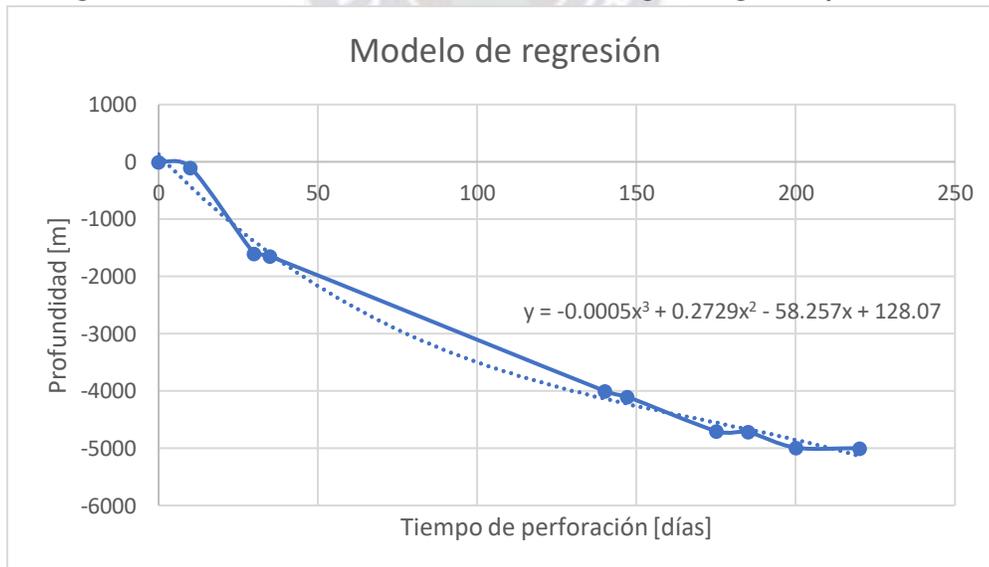
Figura 5. 10: Función del quinto modelo



Fuente: Elaboración propia en base a datos calculados, 2023

Se observa que todos los modelos se aproximan. Por tanto, se puede recomendar usar cualquiera, pero en este caso se utilizará el modelo de las partículas, ya que se aplicaron con otros modelos para ver la diferencia de estos y el funcionamiento de esta propuesta. Graficando de manera polinomial en Excel se tiene:

Figura 5.11: Relación de modelo de Machine learning con regresión polinómica



Fuente: Elaboración propia en base a datos calculados, 2023

4.4.2 Obtención de datos de tiempos de producción con Machine learning

Una vez introducidos los datos en el algoritmo de matlab se obtiene la siguiente tabla:

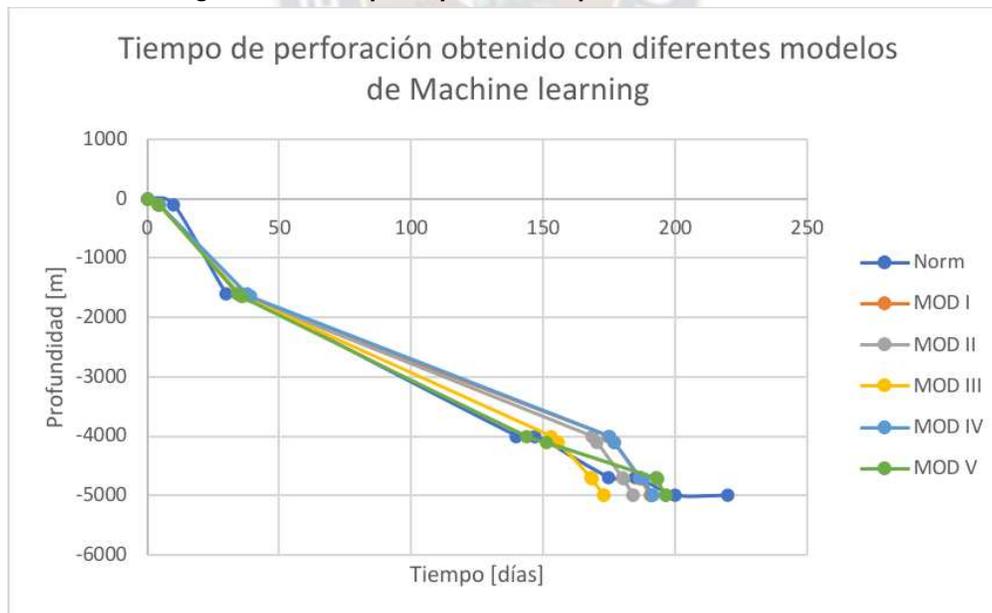
Tabla 5. 3: Datos de tiempos de perforación para diferentes modelos de interacción

Profundidad [m]	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
0	0	0	0	0	0
-100	4,344	4,409	4,361	4,414	4,379
-1600	34,518	34,94	34,889	37,701	34,428
-1650	35,878	36,313	36,3	39,14	35,747
-4000	174,931	168,742	153,174	175,328	143,749
-4100	176,807	170,55	155,721	177,133	151,091
-4700	186,665	180,198	168,28	186,744	192,763
-4720	186,811	180,485	168,457	188,155	193,405
-4990	190,684	184,179	173,077	191,35	196,356
-5000	190,815	184,31	173,231	191,478	196,474

Fuente: Elaboración propia en base a datos calculados, 2023

Gráficamente representando

Figura 5.12: Tiempo de perforación para distintos modelos



Fuente: Elaboración propia en base a datos calculados, 2023

En el anterior gráfico se puede observar la predicción de los nuevos tiempos con respectivas profundidades obtenidas con el Machine learning pero es necesario escoger el modelo más adecuado. Relacionando datos se observa:

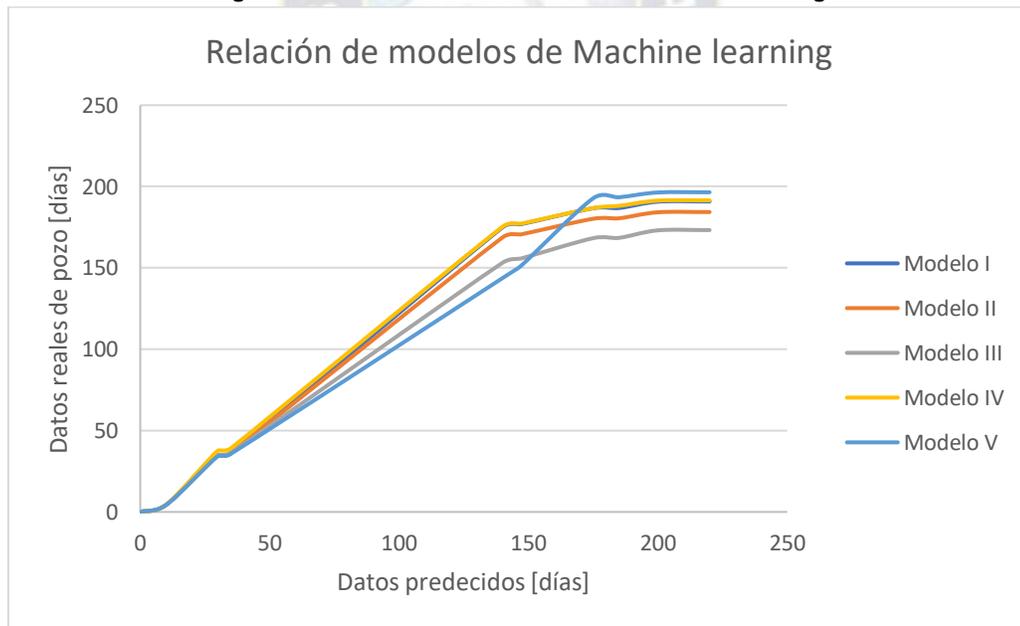
Tabla 5. 4: Datos de varios modelos de predicción de presión

Tiempo (Hrs)	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
0	0	0	0	0	0
10	4,344	4,409	4,361	4,414	4,379
30	34,518	34,94	34,889	37,701	34,428
35	35,878	36,313	36,3	39,14	35,747
140	174,931	168,742	153,174	175,328	143,749
147	176,807	170,55	155,721	177,133	151,091
175	186,665	180,198	168,28	186,744	192,763
185	186,811	180,485	168,457	188,155	193,405
200	190,684	184,179	173,077	191,35	196,356
220	190,815	184,31	173,231	191,478	196,474

Fuente: Elaboración propia en base a datos calculados, 2023

Gráficamente

Figura 5.13: Relación de modelos de Machine learning



Fuente: Elaboración propia en base a datos calculados, 2023

4.4.3 Obtención de las funciones de los modelos

Para la obtención de las funciones se utiliza el regresor de Excel en base a la siguiente ecuación polinómica:

$$h = ABS(at^3 + bt^2 + ct + d)$$

Dónde h es la profundidad alcanzada y el tiempo de perforación para determinar el TNP. Los valores se obtienen automáticamente con el regresor de Excel: Se obtienen las siguientes funciones:

Modelo I: Sin problemas de fallas y mantenimientos al 20%

$$h = ABS(-0,00047 \times t^3 + 0,2809t^2 - 57,481t + 95,01)$$

Modelo II: Con pocos problemas de fallas y mantenimientos al 30%

$$h = ABS(-0,0005 \times t^3 + 0,2729t^2 - 58,257t + 128,07)$$

Modelo III: Con pocos problemas de fallas y mantenimientos al 40%, y considerando insurgencias del clima

$$h = ABS(-0,0005071 \times t^3 + 0,2729t^2 - 58,257t + 128,07)$$

Modelo IV: Con regulares problemas de fallas y mantenimientos al 50%, sin considerar insurgencias del clima

$$h = ABS(-0,00051 \times t^3 + 0,2778t^2 - 61,128t + 128,07)$$

Modelo V: Con regulares problemas de fallas y mantenimientos al 60%, paro operativo y considerando insurgencias del clima

$$h = ABS(-0,00047 \times t^3 + 0,2529t^2 - 62,257t + 131,07)$$

El tiempo mínimo alcanzado de perforación sin ningún Tiempo no productivo, será la pendiente de la curva de profundidad y tiempo, lo cual puede obtenerse con la siguiente relación:

$$\frac{dh}{dt} = 0$$

$$\frac{dh}{dt} = \frac{d[ABS(at^3 + bt^2 + ct + d)]}{dt}$$

$$3at^2 + 2bt + c = 0$$

Aplicando ecuaciones cuadráticas.

$$t^2 + \frac{2b}{3a}t + \frac{c}{3a} = 0$$

$$t_{min} = \frac{-\frac{2b}{3a} - \sqrt{\left(\frac{2b}{3a}\right)^2 - \frac{4c}{3a}}}{2}$$

$$t_{min} = \frac{-\frac{2b}{3a} + \frac{2}{3a}\sqrt{b^2 - 3ac}}{2}$$

Luego el tiempo mínimo de perforación, donde no se presente ninguna dificultad será:

$$t_{min} = \frac{1}{3a}(\sqrt{b^2 - 3ac} - b)$$

Pero necesitaremos más que todo determinar el tiempo con determinados valores de profundidad, lo cual podemos utilizar la fórmula de Newton Rapson:

$$x_{r+1} = x_r - \frac{f(x)}{f'(x)}$$

En este caso, para el tiempo sería:

$$t_{r+1} = t_r - \frac{f(t)}{f'(t)}$$

Para $f(t)$ se tiene:

$$f(t) = h - (at^3 + bt^2 + ct + d)$$

Para $f(t)$ se tiene:

$$f'(t) = -(3at^2 + 2bt + c)$$

Reemplazando en la fórmula de Newton Rapson:

$$t_{r+1} = t_r + \frac{h - (at^3 + bt^2 + ct + d)}{3at^2 + 2bt + c}$$

Se desea entonces calcular en que tiempo promedio se alcanzará la profundidad con bajos tiempos no productivos.

Entonces considerando los factores del tercer modelo se tiene:

$$t_{r+1} = t_r + \frac{-4500 - (-0,0005071t^3 + 0,2729t^2 - 58,257t + 128,07)}{-0,001521 * 3 * t^2 + 0,5458t - 58,257}$$

Para 4500 m de profundidad y 120 días, dándonos cómo parámetro se tiene:

$$120 = 120 + \frac{-4500 - (-0,00047(120)^3 + 0,2729(120)^2 - 58,257(120) + 128,07)}{-0,0005071 * 3 * (120)^2 + 0,2729 * 2 * (120) - 58,257}$$

$$120 = 167.0.91 \quad \text{son diferentes:}$$

Iterando varias veces se tiene:

$$\begin{aligned}
 159 &= 142.75 && \text{son diferentes} \\
 150.743 &= 149.424 && \text{son diferentes} \\
 150 &= 150 && \text{son iguales}
 \end{aligned}$$

Por tanto, el tiempo aproximado es de 150 días

Calculando el tiempo, pero con un modelo con mayor perjuicio operativo que es el quinto modelo, se tiene nuevamente:

Considerando los factores del quinto modelo y reemplazando en la ecuación, se tiene:

$$t_{r+1} = t_r + \frac{-4500 - (-0,00047 \times t^3 + 0,2529t^2 - 62.257t + 131.07)}{-0,00047 * 3 * t^2 + 0,2529 * 2 * t - 62.257}$$

Pero para 150 días dándonos cómo parámetro se tiene:

$$150 = 150 + \frac{-4500 - (-0,00047 \times (150)^3 + 0,2529(150)^2 - 62.257(150) + 131.07)}{-0,00047 * 3 * (150)^2 + 0,2529 * 2 * (150) - 62.257}$$

$$150 = 146.447 \text{ son diferentes:}$$

Iterando varias veces se tiene:

$$146.447 = 146.767 \text{ son diferentes}$$

$$146.767 = 146.74 \text{ son diferentes}$$

$$146.74 = 146.74 \text{ son iguales}$$

Por tanto, el tiempo aproximado es de 119.94 días

El tiempo no productivo para ese tramo es de

$$TNP = t_{\min \text{ MOD } 5} - t_{\min \text{ MOD } 3}$$

$$TNP = 150 - 146.74$$

$$TNP = 3.26 \text{ (días inoperativos)}$$

Se predice entonces que para 4500 (m) no se operará 3.26 días debido a mantenimientos, fallas operativas o insurgencias del clima.



4.5 VALIDACIÓN DEL MODELO

4.5.1 Desarrollo analítico del modelo

El número máximo de nodos establece el número máximo de nodos de predicción para evitar el sobreajuste al limitar la complejidad del árbol. Después del segundo intervalo de recopilación de datos, se utilizó una evaluación empírica de varias opciones de parámetros para encontrar la configuración ideal para cada parámetro por separado. Este método permitió capturar la dinámica y fluctuaciones de cada parámetro. Se utiliza las ecuaciones (5.1) y (5.2), para la predicción y clasificación de vibraciones torsionales.

$$DOC = 16,37 \frac{BOP}{RPM} \quad (5.1)$$

Obteniendo la siguiente tabla con los datos de perforación se tiene:

Tabla 5. 5: Variación de datos de perforación

P10	DOC I	DOC II	DOC III	DOC IV
0	16,55017886	16,17344132	16,50084037	16,2401971
10	16,39392932	15,14901276	17,92626264	14,9488438
30	16,37586253	15,18219213	17,92379221	14,95090419
35	18,0337821	14,30152845	19,96618662	13,42153638
140	17,92888242	14,39117934	19,19152835	13,96329126
147	17,52936332	14,75144369	15,85884885	16,89762622
175	17,53883454	14,65622008	15,92563455	16,82676437
185	17,42005136	14,80674413	15,95265487	16,7982635
200	17,41694443	14,81001196	15,95373871	16,79712228

Fuente: Elaboración propia en base a datos calculados, 2023

$$SSI = \frac{Max\ RPM - Min\ RPM}{PromRPM} \quad (5.2)$$

Para aplicar recurrimos a la siguiente tabla deducida:

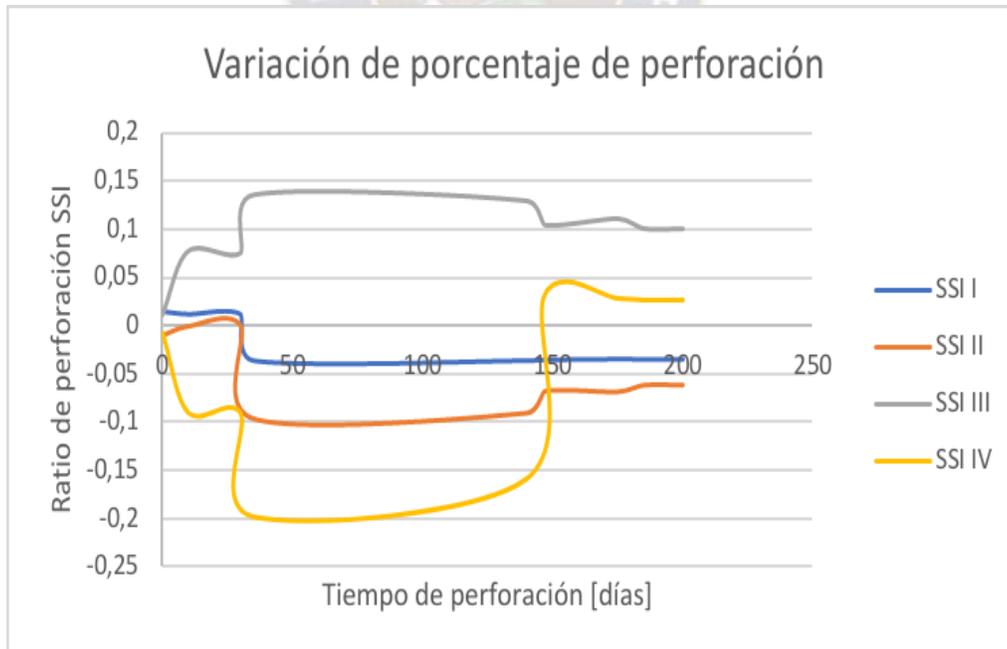
Tabla 5. 6: Variación reducida de datos de perforación

P10	SSI I	SSI II	SSI III	SSI IV
0	0,014852051	-0,010946408	0,012079772	-0,007960878
10	0,012151228	-0,001460711	0,077476236	-0,090754066
30	0,012051364	-0,000358063	0,075291622	-0,090616529
35	-0,036016795	-0,096720884	0,134878935	-0,197939682
140	-0,036026336	-0,090899896	0,128657009	-0,158684313
147	-0,035255668	-0,068400301	0,104015503	0,0317201
175	-0,034446332	-0,068939824	0,110473007	0,027518608
185	-0,034706013	-0,06215151	0,100283459	0,025823691
200	-0,034681773	-0,061973312	0,100063338	0,025755764

Fuente: Elaboración propia en base a datos calculados, 2023

Graficando el ratio de perforación se tiene:

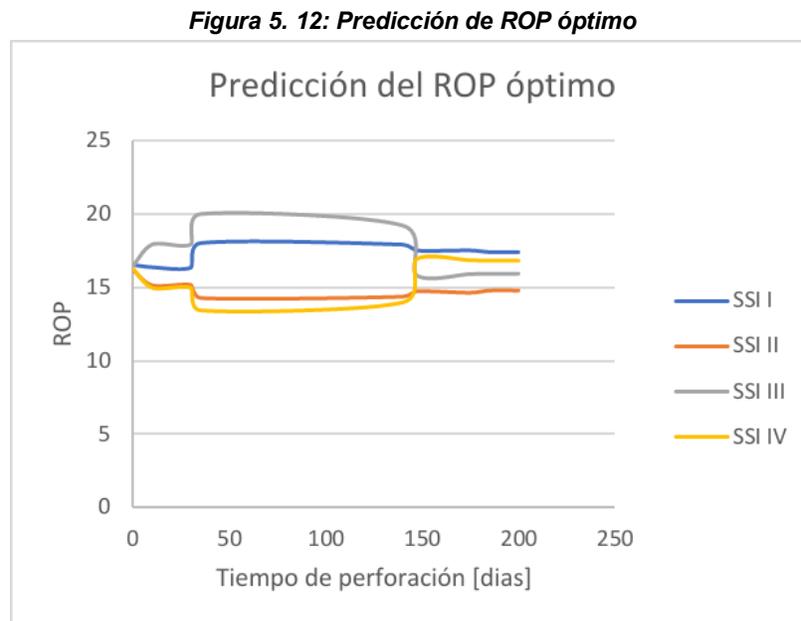
Figura 5. 11: Variación de porcentaje de perforación



Fuente: Elaboración propia en base a datos calculados, 2023

Se puede aceptar el tercer modelo que es más apropiado debido a que la tasa de perforación es positiva y es más real en cambio las otras son negativas y significa que no se va a llegar a perforar totalmente en esos tiempos determinados.

Graficando la variación del ROP se tiene:



Fuente: Elaboración propia en base a datos calculados, 2023

Se observa que el tercer modelo es más aceptable ya que tiene mayor ROP en el tiempo de perforación.

Para la validación final se aplica la siguiente ecuación con los datos obtenidos para los trabajos de perforación

$$RMSE = \left(\frac{(Y_{real} - Y_{predicción})^2}{N} \right)^{0,5} \quad (5.1)$$

Obteniendo la siguiente tabla a partir de la anterior ecuación se puede observar lo siguiente:

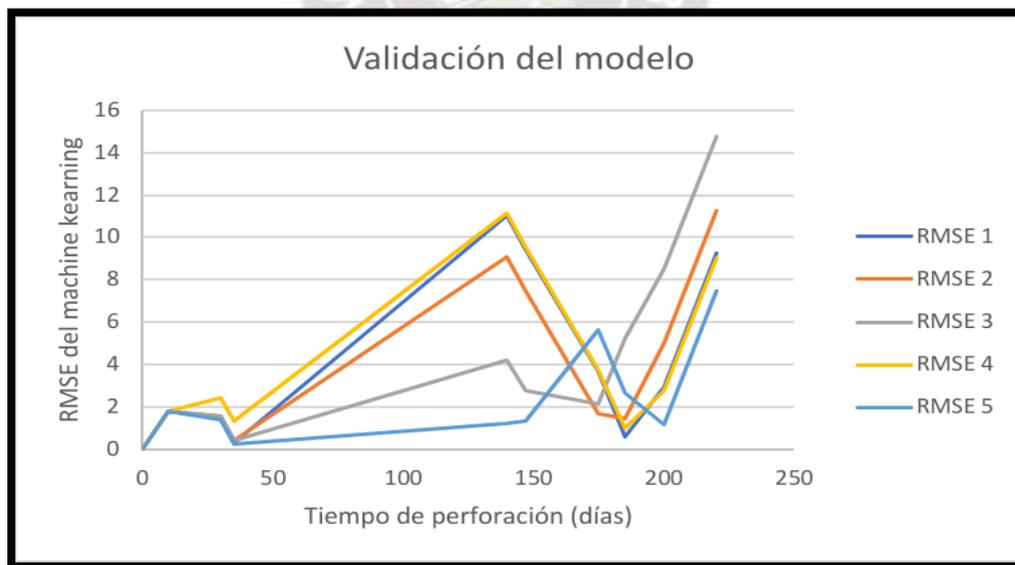
Tabla 5. 7: Variación de datos de perforación

Tiempo (días)	RMSE 1	RMSE 2	RMSE 3	RMSE 4	RMSE 5
0	0	0	0	0	0
10	1,788584245	1,76802944	1,783208373	1,766448301	1,777516273
30	1,428717047	1,562165164	1,546037548	2,435270026	1,400256548
35	0,277647979	0,415207057	0,411096096	1,309182951	0,236222141
140	11,04615209	9,089018451	4,16598459	11,17169452	1,185537895
147	9,425801022	7,44716389	2,757822347	9,528891273	1,293687791
175	3,688796891	1,643751928	2,125050588	3,713778884	5,617153808
185	0,572688484	1,427768364	5,231355933	0,997698602	2,657894373
200	2,945977868	5,003039486	8,513800144	2,735370176	1,152333979
220	9,229107351	11,28616897	14,78965639	9,019448342	7,439574423

Fuente: Elaboración propia en base a datos calculados, 2023

Graficando

Figura 5. 13: Validación del modelo

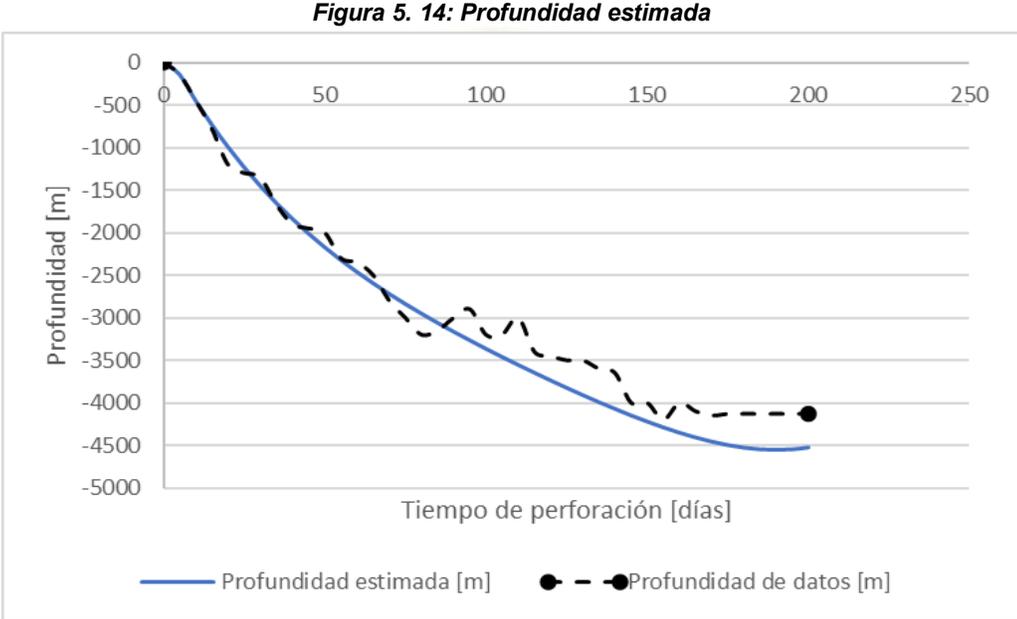


Fuente: Elaboración propia en base a datos calculados, 2023

Se coge entonces el modelo que tenga menos dispersión en el valor, se observa que es la curva ploma, el cual pertenece al tercer modelo para predecir los tiempos no productivos de manera exacta y aproximada.

Se obtienen las siguientes profundidades utilizando el modelo (VER ANEXO E)

Graficando se obtiene:



Fuente: Elaboración propia en base a datos calculados, 2023

De acuerdo al modelo formado a partir de los datos con Machine learning, se calcula el tiempo en el cual se llegará a la profundidad deseada y se estima que la máxima profundidad es de 4500 metros, ya que el modelo opta al mínimo valor de manera automática según la recomendación del programa y no así los 5000 m que está en algunos otros datos.

Validando la presión de fondo total

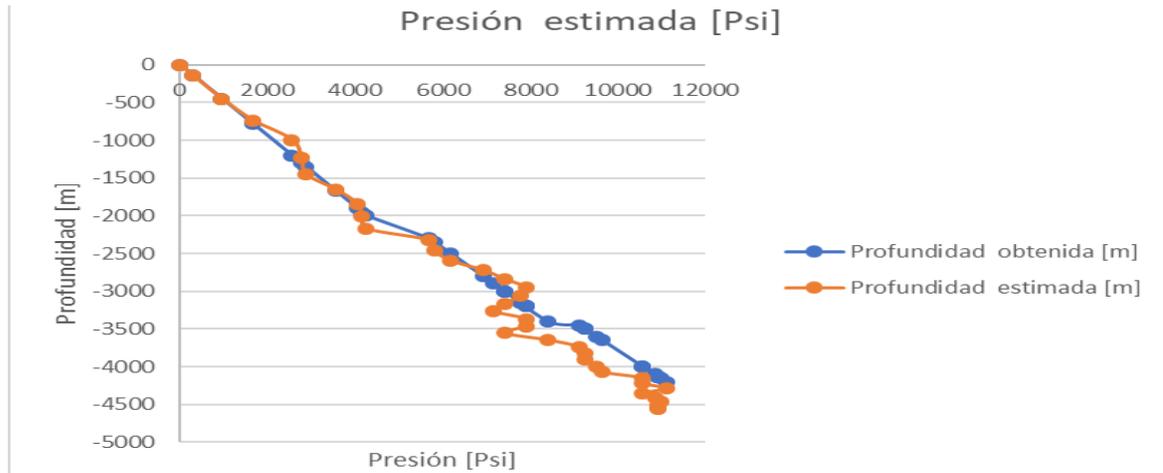
Tabla 5. 8: Datos de validación de presión de fondo total

ΔP [Psi]	Profundidad obtenida [m]	Profundidad estimada [m]
0	0	0
298.48	-140	-143.094
959.4	-450	-450.72
2878.2	-1350	-1450.53
4157.4	-1950	-2012.68
4264	-2000	-2173.42
5688.176	-2300	-2323.31
6182.8	-2500	-2595.63
6924.736	-2800	-2720.38
7419.36	-3000	-2838.88
7913.984	-3200	-2952.03
7913.984	-3200	-3365.23
7913.984	-3200	-3461.29
7419.36	-3000	-3555.12
9252.88	-3500	-3909.65
9517.248	-3600	-3992.52
9649.432	-3650	-4072.5
10574.72	-4000	-4352.2
10839.088	-4100	-4408.35
10971.272	-4150	-4457.12
10918.3984	-4130	-4497.4
10918.3984	-4130	-4547.62
10918.3984	-4130	-4525.03

Fuente: Elaboración propia en base a datos calculados, 2023

Graficando:

Figura 5. 18: Validación de presión promedio del pozo



Fuente: Elaboración propia en base a datos calculados, 2023

Para los tiempos no productivos tomamos los tiempos de la curva más alejada de la curva promedio obtenida los cuales serían

Tabla 5. 9: Tiempos no productivos y tiempos óptimos

Profundidad (m)	Tiempo mínimo [HRS]	Tiempo optimo [HRS]	Tiempo no productivo [HRS]
0	0	0	0
-100	10	12	12
-700	25	50	100
-700	30	55	105
-2100	80	105	155
-2100	85	110	160
-3400	135	160	275
-4400	160	205	300
-4400	170	215	310
-4700	180	225	320
-4700	200	245	340

Fuente: Elaboración propia en base a datos calculados, 2023

4.6 PLAN DE RIESGOS

Para evitar tiempos no productivos se propone el siguiente plan de riesgos:

Tabla 5. 10: Plan de Riesgos para evitar TNPS

PERSONAL	RESPONSABILIDADES		
	TIEMPO NORMAL	DURANTE LA EMERGENCIA	DESPUÉS DE LA EMERGENCIA
<p>COORDINADOR DE LA EMERGENCIA</p> <p>Fase de perforación: Jefe de Pozo ("CompanyMan"), o como alternativa el "ToolPusher" de la compañía de perforación. Persona autorizada para comandar toda la situación de emergencia.</p> <p>Para la fase de obra civil será el director Obra.</p> <p>Fase de producción: Supervisor de Producción</p>	<p>Conocer los procedimientos de respuesta establecidos.</p> <p>Mantener inventario actualizado de equipos para atención de emergencias.</p> <p>Mantener inventario de personal auxiliar y Contratistas para emergencias.</p> <p>Asegurar la ejecución de programas de entrenamiento.</p>	<p>Evaluación preliminar de la emergencia.</p> <p>Activación de la brigada de emergencia.</p> <p>Coordinación y logística de las actividades de control.</p> <p>Suministro de equipos de acuerdo al plan de control.</p> <p>Localización y suministro de personal auxiliar / contratistas.</p>	<p>Colaborar en la investigación de la emergencia.</p> <p>Desarrollar actividades para facilitar el establecimiento de las operaciones.</p>

Continúa

Continuación Tabla 5.10

PERSONAL	RESPONSABILIDADES		
	TIEMPO NORMAL	DURANTE LA EMERGENCIA	DESPUÉS DE LA EMERGENCIA
<p>JEFE DE EMERGENCIA</p> <p>Ingenieros supervisores: Personas designadas para estar a cargo de toda la operación de emergencia, informan sobre las operaciones del Plan de Contingencia y mantienen estrecha comunicación con el Jefe de pozo. Organizan el personal de servicio de apoyo, coordinan las fuentes de transporte de materiales y equipos necesarios.</p> <p>Reporta a: Jefe de Turno.</p> <p>En obra civil estará a cargo del Ingeniero Residente.</p> <p>Reporta a: Director de Obra</p> <p>Fase de operación: Operador de la EPF</p> <p>Reporta a: Ingeniero de producción</p>	<p>Conocer sus responsabilidades en el Plan de Contingencia.</p> <p>Mantener inventario actualizado sobre los materiales y equipos de emergencia</p> <p>Verificar la participación de los miembros de la brigada en el proceso de capacitación</p> <p>Participar en simulacros y entrenamiento.</p>	<p>Activación del Plan de Control según el tipo de emergencia.</p> <p>Programación de requerimientos de suministros, según el Plan de Control.</p> <p>Asignación de responsabilidades a la Brigada de Emergencia.</p> <p>Administración de materiales y equipos.</p>	<p>Administración de materiales y equipos.</p> <p>Presentar informe sobre gastos (de insumos) y estado de equipos después de la emergencia para reposición.</p> <p>Evaluar el comportamiento de la Brigada para mejorar los procedimientos.</p>

Continua

Continuación Tabla 5.10

PERSONAL	RESPONSABILIDADES
----------	-------------------

	TIEMPO NORMAL	DURANTE LA EMERGENCIA	DESPUÉS DE LA EMERGENCIA
<p>BRIGADISTAS</p> <p>Función: Realizar las actividades asignadas a la Brigada de Emergencia, en concordancia con el Plan de Control.</p> <p>Reportan a: Supervisor de Operaciones, Ingeniero residente u operador del área según la etapa en la cual se encuentre en el proyecto</p>	<p>Colaborar en inspección de riesgos y revisión de equipos de protección.</p> <p>Colaborar en labores de capacitación de empleados.</p> <p>Participar en simulacros y entrenamientos.</p>	<p>Conducción de vehículos durante la emergencia.</p> <p>Operación de equipos de medición (explosímetros).</p> <p>Alistamiento de equipos, según Plan de Control.</p> <p>Operación de barreras, equipos de recolección, extintores y demás equipos de contraincendio.</p> <p>Coordinación de actividades de limpieza una vez terminada la emergencia.</p>	<p>Inspeccionar las áreas afectadas y aledañas para asegurar el control de riesgos.</p> <p>Colaborar con el mantenimiento de los equipos utilizados.</p>
<p>COORDINADOR DE MANTENIMIENTO (JEFE DE MANTENIMIENTO)</p> <p>Función: Mantener operativos los equipos e instalaciones.</p> <p>Reporta a: Coordinador en escena.</p>	<p>Mantener los equipos en buen estado.</p> <p>Ejecutar programa de mantenimiento preventivo</p>	<p>Apoya las operaciones de los grupos de emergencia.</p> <p>Controla el uso de equipos que generan riesgo de incendio o explosión.</p> <p>Prevé daño y deterioro de equipos por sobre uso.</p> <p>Realiza inspección y mantenimiento de los equipos y herramientas durante la emergencia.</p>	<p>Participa en la evaluación del Plan de Contingencia.</p> <p>Hace mantenimiento a los equipos usados en la emergencia.</p>

Continúa

Continuación Tabla 5.10

PERSONAL	RESPONSABILIDADES
-----------------	--------------------------

	TIEMPO NORMAL	DURANTE LA EMERGENCIA	DESPUÉS DE LA EMERGENCIA
<p>PRIMEROS AUXILIOS</p> <p>Función: Mantener la salud del personal, examinar y tratar lesionado.</p> <p>Reporta a: Coordinador en escena.</p>	<p>Mantener actualizado el listado de paramédicos y centros de atención medica.</p> <p>Participar en simulacros y entrenamientos.</p> <p>Mantener inventario de equipos y medicamentos de primeros auxilios.</p> <p>Diseñar y ejecutar programas de entrenamiento en primeros auxilios.</p>	<p>Verifica medidas preventivas necesarias (hoja de seguridad de los productos almacenados). Esta alerta a la ocurrencia de accidentes.</p> <p>Establece sistemas ágiles de atención de pacientes.</p> <p>Coordina la evacuación de heridos y activa los procedimientos necesarios.</p> <p>Proporciona primeros auxilios y tratamiento a heridos y enfermos.</p> <p>Envía a hospitalización personas que requieran tratamiento especial.</p>	<p>Participa en la evaluación del Plan de Contingencia.</p> <p>Presenta informes finales de afectados durante la emergencia.</p> <p>Evalúa los procedimientos de sus funciones en la emergencia.</p>

Fuente: Elaboración propia en base a datos calculados, 2023

CAPÍTULO 6: COSTOS DEL PROYECTO

5.1 INTRODUCCIÓN AL ANÁLISIS

La evaluación económica se basa en el costo total de los equipos de procesos de perforación de pozos en el sub Andino.

5.2 ANÁLISIS DE COSTOS

5.2.1 Costos fijos

A continuación, se presentan los costos fijos considerando los costos de simulación y los costos de los equipos en la perforación:

Tabla 6. 1: Análisis de costos fijos

COSTOS FIJOS EN BOLIVIANOS		
	Mensual	Tipo
COSTOS FIJOS		
SERVICIOS BÁSICOS	10.000	Adm
MANO DE OBRA DIRECTA (MOD)	37.500	Adm
MANO DE OBRA INDIRECTA (MOI)	14.000	Adm
SEGURIDAD INDUSTRIAL	12.500	Adm
MANTENIMIENTO DE DUCTOS	30.000	Operativo
GASTOS GRALES. DE LEVANTAMIENTO DE DATOS	5.000	Admin
IMPUESTOS SERVICIO DE INGENIERÍA	6.000	
TOTAL COSTO FIJO MES	115.000	

Fuente: Elaboración propia en base en el análisis de perdida y propuesta, 2023

El costo fijo de levantamiento del proyecto para la predicción de tiempos no productivos durante la perforación de manera es de 115.000 Bolivianos.

5.2.2 Costos Variables de predicción de tiempos no productivos

A continuación, se presentan los costos variables considerando la simulación y mantenimiento de perforación

Tabla 6. 2: Costos variables

COSTOS VARIABLES [Bs]			
COSTOS VARIABLES	Cantidad	V/r Unit	Mensual
Accesorios	10	200,00	2.000
Válvulas	5	3.500,00	17.500
Daños por NPT en la perforación	5	1.400,00	7.000
Computadoras portátiles	2	10.000,00	20.000
Bombas	3	14.000,00	42.000
Mantenimiento en operación	1624,5	17,50	28.479
Equipos de seguridad	10	1.000,00	10.000
Equipos electrónicos	6	4.000	24.000
TOTAL COSTO VARIABLE MES			150.979

Fuente: Elaboración propia en base en el análisis de perdida y propuesta, 2023

El costo variable de levantamiento del proyecto para el mantenimiento y prevención de tiempos no productivos de manera mensual es de 150.000 Bolivianos

Reduciendo el costo por daños de NPT:

Tabla 6. 3: Costos variables sin pérdida por NPT

COSTOS VARIABLES [Bs]			
	Cantidad	V/r Unit	Mensual
COSTOS VARIABLES			
Accesorios	10	200,00	2.000
Válvulas	5	3.500,00	17.500
Daños por NPT en la perforación	2	1.400,00	2.800
Computadoras portátiles	2	10.000,00	20.000
Bombas	3	14.000,00	42.000
Mantenimiento en operación	-	-	-
Equipos de seguridad	10	1.000,00	10.000
Equipos electrónicos	6	4.000	24.000
TOTAL COSTO VARIABLE MES			11.300

Fuente: Elaboración propia en base en el análisis de pérdida y propuesta, 2023

5.3 COMPARACIÓN DE PÉRDIDAS DE TIEMPOS NO PRODUCTIVOS

Distribuyendo los costos con NPT y sin NPT para 30 días de operación:

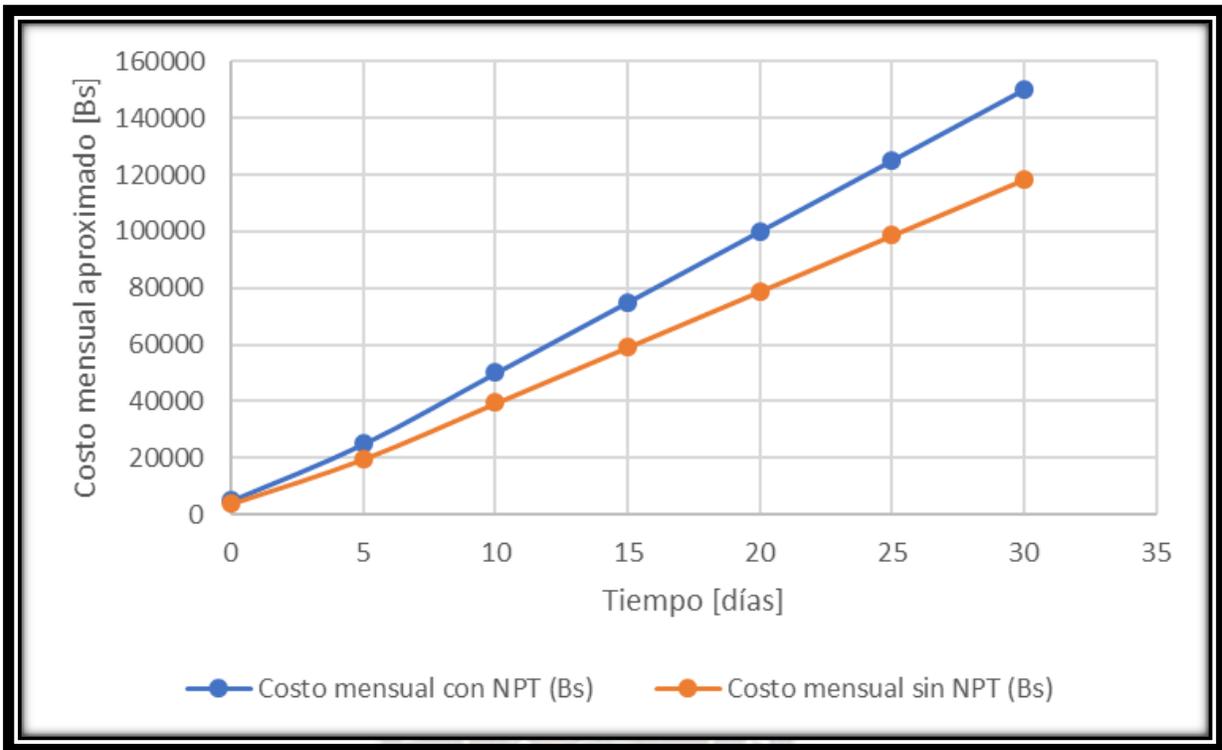
Tabla 6. 4: Comparación de costos

Tiempo (Días)	Costo mensual con NPT (Bs)	Costo mensual sin NPT (Bs)
0	5.000	3.943,33
5	25.000	19.716,65
10	50.000	39.433,30
15	75.000	59.149,95
20	100.000	78.866,60
25	125.000	98.583,25
30	150.000	118.300,00

Fuente: Elaboración propia, 2023

Graficando se tiene:

Figura 6. 1: Comparación de pérdidas



Fuente: Elaboración propia, 2023

Para la recta de costo mensual se tiene aplicando el concepto de dos puntos que pasan por una recta:

$$\frac{y - y_2}{x - x_2} = \frac{y_2 - y_1}{x_2 - x_1}$$

Obteniendo la recta de costo con NPT:

$$y = \frac{y_2 - y_1}{x_2 - x_1} (x - x_2) + y_2$$

$$y = \frac{150.000 - 5.000}{30 - 0} (x - 30) + 150.000$$

$$y = 4.833,33x + 5.000$$

Expresando como función superior $f(x_2)$, se tiene:

$$f(x_2) = 4.833,33x + 5.000$$

De la misma manera para la función de costo sin NPT se tiene la función inferior:

$$y = \frac{118.300 - 3.943,33}{30 - 0}(x - 30) + 118.300$$

$$f(x_1) = 3.811,89x + 3.943,33$$

Pero el área de la curva, entre las dos rectas representa la pérdida total que se controla con la simulación de Machine learning. Aplicando entonces el concepto del área entre dos curvas se tiene:

$$Pérdida_{NPT} = \frac{1}{t} \int_a^b [f(x_2) - f(x_1)] dx$$

Reemplazando para 30 días las funciones respectivamente:

$$Pérdida_{NPT} = \frac{1}{30} \int_0^{30} [4.833,33x + 5.000 - 3.811,89x - 3.943,33] dx$$

$$Pérdida_{NPT} = \frac{1}{30} \int_0^{30} [1.021,44x + 1.056,67] dx$$

$$Pérdida_{NPT} = \frac{1}{30} (510,72x^2|_0^{30} + 1.056,67x|_0^{30})$$

$$Pérdida_{NPT} = \frac{(510,72(30^2 - 0^2) + 1.056,67(30 - 0))}{30}$$

La pérdida promedio es:

$$Pérdida_{NPT} = 16356,67 \text{ Bs al mes}$$

5.4 ANÁLISIS DE COSTO Y BENEFICIO

La siguiente tabla puede usarse como indicador para determinar si los costos de implementación de predicción de tiempos no productivos tienen los siguientes beneficios:

Tabla 6. 5: Interpretación de Costo y beneficios

CRITERIO	DESCRIPCION	SIGNIFICADO
B/C > 1	Los ingresos son mayores que los egresos	El proyecto es aconsejable
B/C = 1	Los ingresos son iguales que los egresos	El proyecto es indiferente
B/C < 1	Los ingresos son menores que los egresos	El proyecto no es aconsejable

Fuente: Elaboración propia, 2023

Por lo tanto, usando la ecuación:

$$\frac{B}{C} = \frac{\text{Beneficios}}{\text{Inversion inicial}} \quad (6.3)$$

Por otra parte, se sabe que la perforación no genera ningún ingreso, solo el producto que se produce y en ese caso se utiliza el dinero de ahorros de venta de gas mínimo destinado de 2 millones de bolivianos anuales para proyectos nuevos.

Para los cuatro años de financiamiento:

$$\frac{B}{C} = \frac{(2.000.000 \text{ Bs/año}) * (4 \text{ año})}{5.708.244 \text{ Bs}}$$

$$\frac{B}{C} = 1,40$$

Sobra el 40 % del presupuesto planteado, por lo tanto, el proyecto es factible ya que sobrar  dinero despu s con la implementaci n del proyecto de control de tiempos no productivos.



CAPÍTULO 7: CONCLUSIONES Y RECOMENDACIÓN

6.1 CONCLUSIONES

Se llegó a las siguientes conclusiones con el proyecto realizado:

- Se ha podido utilizar la tecnología de inteligencia artificial de red neuronal para predecir la probabilidad de NPT en la planificación de pozos en el sub Andino Sur.
- Se ha creado un modelo, recopilando las características del lodo, la geometría y los parámetros de perforación de los pozos ya perforados en el Sub Andino sur.
- Se determinó eficazmente los tiempos de perforación mediante la simulación del modelo propuesto con datos de pozos con y sin NPT ver tabla 5.7, para la planificación de futuros pozos aplicando el software Matlab.
- Se pudo desarrollar un plan de riesgos a partir de la simulación para evitar futuros NPT's en la planificación de nuevos pozos en el bloque Sub Andino.
- El análisis de factibilidad económico del proyecto indica que el proyecto se puede realizar fácilmente con un bajo presupuesto debido a que el dinero solo se destina en la capacitación de profesionales dentro de la empresa de yacimientos petrolíferos fiscales y se recupera en menos de 2 años.
- Se logró estimar eficazmente los tiempos de perforación óptima para evitar el incremento de tiempos no productivos.

6.2 RECOMENDACIONES

- Es recomendable enfocar la ingeniería de la perforación con la simulación numérica, ya que en Bolivia todavía no se han profundizado estos temas y no se han alcanzado grandes logros en investigaciones; por tanto, es importante tomar en cuenta la propuesta de nuevas ideas y el desarrollo de nuevas teorías que mejoren la ciencia de la perforación. En este proyecto de grado solo se hizo un análisis simple en el control de los NPTS de perforación, queda recomendado investigar en el área de cementación, en el área de perforación direccional y el área de control de reventones en el pozo aplicando esta técnica denominada Machine Learning.
- A la empresa de YPFB y la Agencia Nacional de Hidrocarburos se recomienda capacitar a los trabajadores dedicados en el área de análisis de datos concursos especializados en Matlab, Python y Machine Learning para generar una competencia internacional con las demás empresas petroleras y lograr una eficiencia en el manejo de los costos para no desperdiciar recursos económicos.
- Los parámetros de perforación y los tiempos no productivos necesitan controlarse día a día de manera automática y con la aplicación de softwares avanzados, ya no de una manera anticuada como el control de planillas y con registros simplemente con fechas, ya que esta tecnología puede tener bastantes errores y se necesita de una Inteligencia artificial capaz de predecir a partir de una base de datos, que en este caso fueron las profundidades que realizó Repsol para poder predecir a partir de estos nuevos valores de perforación y se podrá predecir el tiempo en que se tardará en perforar un nuevo pozo cerca a ese campo.

BIBLIOGRAFÍA

- AADE group. (2015). *Independent Third Party Verification of BOP for the GOM*.
- Amin, & Rodin. (1998). *Traffic Prediction and Management via RBF Neural Nets and Semantic Control*. Minesotta: Computer-Aided Civil and Infrastructure Engineering.
- Ayala, D. (2017). *Impacto del Tiempo no Productivo en Operaciones de Perforación y Análisis de los Datos Mediante la Prueba de Chicuadrado*. Retrieved from Revista Fuentes el Reventón Energético : [researchgate.net/publication/317059018_Impacto_del_Tiempo_no_Productivo_en_Operaciones_de_Perforacion_y_Analisis_de_los_Datos_Mediante_la_Prueba_de_Chicuadrado](https://www.researchgate.net/publication/317059018_Impacto_del_Tiempo_no_Productivo_en_Operaciones_de_Perforacion_y_Analisis_de_los_Datos_Mediante_la_Prueba_de_Chicuadrado)
- Bagnato, J. I. (2018). *Aplicaciones del Machine Learning*. NP.
- Barakat, M. (2018). *Integrating risk management concepts into the drilling non-productive time*. Texas: Journal of Petroleum Exploration and Production.
- Belda, C. F. (2016). *LOS MODELOS DE SIMULACIÓN: UNA HERRAMIENTA MULTIDISCIPLINAR DE INVESTIGACIÓN*. Barcelona: Universidad Pontificia de Comillas.
- Chollet, F. (2017). *Deep Learning with Python*. Manning Publications.
- Cruz, C., Mombrú, A., & Cangini, C. (2003). *Hábitat de hidrocarburos en el Pie de Sierra de la Faja Corrida*. Tarija: Simposio Bolivariano Exploración Petrolera en las Cuencas.
- González, -C. (2018). EN QUÉ CONSISTE EL APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING) Y QUÉ ESTÁ APORTANDO A LA NEUROCIENCIA COGNITIVA. <https://www.cienciacognitiva.org/>, 2.
- Haefner, N., & Wincent, J. (2021). *Artificial intelligence and innovation management: A review, framework, and research agenda*. Retrieved from sciencedirect: <https://www.sciencedirect.com/science/article/pii/S004016252031218X>
- Martinez, J. (2018). Aprendizaje Automático . *The European Space Agency (ESA)*.

- Martínez, J. D., & Poveda, J. S. (2021). *Optimización en la planeación de pozos por medio de la predicción de tiempos, costos y NPT'S, aplicando un modelo de machine learning para la campaña de perforación de Castilla y Castilla norte 2020*. Castilla : Fundación Universidad de América.
- Mitchell, T. M. (1997). *Does Machine Learning Really Work?* AI Magazine,.
- Ojeda Vargas, D. A. (2021). *GENERACIÓN DE UN MODELO PREDICTIVO PARA EVENTOS DE PEGA DE*. Bogotá: Universidad De Los Andes.
- REPSOL. (2020). *Informe de Estratigrafía del bloque Sub Andino*. Tarija: YPF.
- Russell, S. J., & Norvig, P. (2008). *INTELIGENCIA ARTIFICIAL, UN ENFOQUE MODERNO*. CDM: COPIBOOK, S.L.
- Sanchez, B. (2018). Machine Learning for Scent: Learning Generalizable Perceptual Representations of Small Molecules. *arxiv.org*.
- Shwartz, S., & Shai, B. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge: Cambridge University Press.
- Vargas, D. A., & Zuly, C. (2018). *Modelo matemático para determinar presión permitida de pérdidas de filtrado de lodo controladas*. Bogota: Universidad Industrial de Santander.
- Velogig. (2018). *¿Qué es el Machine Learning y cómo es su proceso?* Retrieved from velogig.com
- Whiticar, M. (1994). *Correlation of natural gases with their sources. The petroleum system from source to trap*. American Association of Petroleum.
- Yacimientos Petrolíferos Bolivianos. (2019). *Informe litológico del Bloque Sub Andino Sur*. Tarija.

GLOSARIO

ANFIS

Sistema adaptativo de inferencia neuro difusa

KPI

Indicador clave de desempeño

NPT:

Tiempo no productivo del inglés no productive time

PSO

Optimización por nube o enjambre de partículas

ANEXOS

ANEXOS A: REQUISITOS DE CONTRATO POR PARTE DE YPFB CHACO



LIC-150080
PLIEGO DE ESPECIFICACIONES ADMINISTRATIVAS
SERVICIOS DE FLUIDOS DE PERFORACION, TERMINACIÓN E INTERVENCIÓN DE POZOS

1. Instrucciones

YPFB CHACO S.A. busca contratar los servicios detallados en la presente Licitación mediante su procedimiento de Sobre Cerrado. Dicho procedimiento implica que se considerarán únicamente aquellas ofertas técnicas y económicas que cumplan con los requisitos presentados en este documento.

2. Alcance

Prestación de los servicios de fluidos (lodos) de perforación, terminación e ingeniería, necesarios para el cumplimiento del Cronograma de Perforación e Intervención de Pozos gestión 2016 y 2017.

Estos servicios incluyen la planificación, programación, suministro y logística de los materiales específicos necesarios para la preparación y mantenimiento de lodos de perforación, terminación e intervención; además, del soporte técnico de personal para el servicio en campo (Ingenieros), soporte técnico de diseño de los fluidos, laboratorio en SCZ y soporte de su Matriz.

Responsabilidades de YPFB Chaco:

- Alimentación y alojamiento del personal del Contratista
- Carguio y descarguio de equipos y materiales del Contratista en el pozo.

Responsabilidades del Contratista:

- El transporte del personal hasta el Área de Operación, incluyendo el vehículo, correrá por cuenta del CONTRATISTA sin costo alguno para YPFB CHACO.
- El costo del personal empezará a correr a partir de su llegada al pozo y no desde su movilización de su Base de Operaciones.
- El transporte de equipos y materiales o productos, desde su base operativa hasta el pozo y viceversa.
- El carguio y descarguio de equipos y materiales o productos del Contratista en su base en SCZ.

Condiciones Contractuales:

Vigencia de contrato:
Dos (2) años, A partir de la suscripción del contrato y fecha requerida de inicio.

Modalidad de Adjudicación:
Adjudicación total; para poder determinar la mejor oferta se compararán los precios ofertados por personal y productos para pozos tipo Profundo, Intermedio y Somero.

Especificaciones Administrativas
1

Fuente: Reglas de Contratos, YPFB CHACO, 2021

**ADJUNTO 2 – LIC-150080
CONTRATO DE SERVICIOS
DE
SERVICIO DE FLUIDOS DE PERFORACIÓN, TERMINACIÓN E INTERVENCIÓN DE
POZOS**

CSS-

Contenido

1. ANTECEDENTES.....	2
2. OBJETO.....	2
3. PLAZO DEL CONTRATO.....	2
4. DEFINICIONES.....	3
5. ANEXOS.....	5
6. REQUISITOS DE INICIO.....	5
7. PERSONAL DEL CONTRATISTA.....	6
8. MOVILIZACIÓN Y DESMOVILIZACIÓN.....	9
9. EQUIPOS Y MATERIALES DEL CONTRATISTA.....	9
10. CUIDADO DE LOS EQUIPOS, MATERIALES E INFORMACION DE YPFB CHACO...	11
11. REPRESENTANTES DE YPFB CHACO.....	11
12. REMUNERACIONES.....	11
13. FACTURACIÓN.....	12
14. PAGOS.....	14
15. EL DERECHO DE YPFB CHACO DE CUESTIONAR CUENTAS Y DE AUDITARLAS..	14
16. IMPUESTOS Y OTRAS CARGAS ADMINISTRATIVAS.....	15
17. SEGUROS.....	15
18. CONTRATISTA INDEPENDIENTE.....	17
19. RELACIÓN ENTRE LAS PARTES.....	17
20. TERMINACIÓN ANTICIPADA DEL CONTRATO.....	17
21. LEGISLACIÓN LOCAL.....	19
22. INFORMACIÓN CONFIDENCIAL.....	20
23. INDEMNIDAD.....	20
24. VIOLACIÓN DE DERECHOS DE PATENTE.....	23
25. GRAVÁMENES.....	24
26. CUMPLIMIENTO NO SATISFACTORIO Y PENALIDADES.....	24
27. LIMITACIÓN A LOS DAÑOS.....	26
28. MATERIAL RADIOACTIVO.....	26
29. CESIÓN Y SUBCONTRATACIONES POR EL CONTRATISTA.....	26
30. CESIÓN POR YPFB CHACO.....	27
31. NOTIFICACIONES.....	27
32. IMPOSIBILIDAD SOBREVINIENTE.....	27
33. RENUNCIAS.....	28
34. ACUERDO INTEGRO.....	28
35. SUCESORES Y CESIONARIOS.....	28
36. OBLIGACIONES SUBSISTENTES.....	28
37. LEY APLICABLE Y RESOLUCIÓN DE CONTROVERSIAS.....	28
38. CONDUCTA ÉTICA.....	29
39. CONFORMIDAD.....	29

Por CONTRATISTA:

Por YPFB CHACO:

CSS-

1

Fuente: Reglas de Contratos, YPFB CHACO, 2021

- 4.8 Día**
Se refiere a los días calendario.
- 4.9 Fecha de Inicio**
Será el Día y la hora en que los equipos, materiales y personal del CONTRATISTA hayan dado cumplimiento a los requisitos de inicio solicitados por YPFB CHACO y que se detallan en el Anexo "A". Dicha Fecha de Inicio deberá ser confirmada por escrito por YPFB CHACO y por el CONTRATISTA utilizando el reporte de operaciones del CONTRATISTA.
- 4.10 Fecha Requerida de Inicio**
Será el día indicado en el Anexo "A" en que el CONTRATISTA debe estar listo, en caso que YPFB CHACO lo requiera, para iniciar operaciones en el primer pozo conforme las condiciones establecidas para la Fecha de Inicio.
- 4.11 Grupo YPFB CHACO**
Serán las siguientes entidades y personas de manera individual o colectiva: YPFB y sus cesionarios, Afiliadas, mandatarios, funcionarios, directores, empleados, asesores, aseguradores o emisores de pólizas; YPFB CHACO y sus Afiliadas, sus socios y sus Afiliadas, los directores, funcionarios, empleados, agentes y aseguradores de todas estas entidades.
- 4.12 Grupo del CONTRATISTA**
Serán las siguientes entidades y personas de manera individual o colectiva: el CONTRATISTA y sus Afiliadas, directores, funcionarios, empleados, subcontratistas, agentes y aseguradores de todas estas entidades.
- 4.13 Líder de Equipo del Proyecto**
Será el responsable por parte de YPFB CHACO de coordinar la ejecución de los Trabajos con el CONTRATISTA.
- 4.14 Lugar de Trabajo**
Será la planchada de cada pozo u otra área requerida por YPFB CHACO para realizar los Trabajos.
- 4.15 Movilización**
Serán todos los preparativos, actividades administrativas, operativas y el desplazamiento de los equipos, materiales y personal del CONTRATISTA, desde la Base Operativa hasta el Lugar de Trabajo y/o desde un Lugar de Trabajo a otro.
- 4.16 NPT**
Es el tiempo no productivo, que se define como el tiempo total perdido sin lograr ningún progreso hacia el objetivo (antes planificado).
- 4.17 Responsable del Contratista**
Persona del Grupo del Contratista ubicada en el Lugar de Trabajo con facultad para resolver cuestiones operativas que surjan a diario entre YPFB CHACO y el CONTRATISTA.
- 4.18 Supervisor de Perforación (Company Man)**
Persona designada por YPFB CHACO que tendrá la autoridad para actuar en nombre de ésta en el Lugar de Trabajo, en cualquier asunto relacionado a los Trabajos, salvo aquellos reservados para el Líder de Equipo del Proyecto.

26.2 Retenciones:

YPFB CHACO podrá, en su única opinión, retener el total o parte de cualquier pago al CONTRATISTA cuando sea necesario para YPFB CHACO prevenir o precautelarse de pérdidas eventuales u ocasionadas, a causa de:

- a. Reclamos o evidencia que indica que probablemente se registren reclamos.
- b. Daños a cualquiera de los miembros del Grupo YPFB CHACO u otros, que hubiese sido ocasionado por culpa grave o dolo del GRUPO CONTRATISTA.
- c. Montos adeudados o que pudieren adeudarse a YPFB CHACO por parte del CONTRATISTA.
- d. Que YPFB CHACO considere que el CONTRATISTA no ha cumplido con cualquiera de las cláusulas del Contrato.
- e. Cualquier otra situación tutelada por el Contrato y/o que pueda de otra manera ser prevista, requerida o dispuesta por las leyes aplicables. Esta retención no podrá aplicarse en caso de un incumplimiento estipulado en la Subcláusula de penalidades.

26.3 Penalidades:

Si, el CONTRATISTA incurriera en cualquiera de los siguientes incumplimientos:

- a) Proveer los materiales fuera de las especificaciones técnicas detalladas en los Anexos del Contrato.
Estos materiales usados no serán pagados por YPFB Chaco.

- b) No disponer el material en boca de pozo del material aprobado y comprometido en el programa de lodos.

YPFB Chaco reportará dicho incumplimiento al Contratista y el CONTRATISTA pagará a favor de YPFB CHACO penalidades Del cincuenta por ciento (50%) del material que no se encuentre disponible en boca de pozo. Dicha penalidad podrá ser descontada por YPFB Chaco del monto adeudado al Contratista por la realización de los Trabajos objeto del Contrato.

Además de las penalidades establecidas, YPFB CHACO será reembolsada y compensada por el CONTRATISTA por todos los costos incurridos que ocasionen dichos incumplimientos.

26.4 Costos incurridos:

YPFB CHACO será reembolsada y compensada por el CONTRATISTA por todos los costos incurridos durante:

1. Tiempos No Productivos (NPT) atribuible al Contratista. Problemas inherentes a los Trabajos realizados en este servicio, siempre y cuando sean atribuibles al Contratista.
2. Incumplimientos de las obligaciones del Contratista, que provoquen una paralización en los Trabajos.

26.5 Material Inadecuado:

Si a sugerencia del Contratista, YPFB CHACO autorizara el uso de algún material señalado en el Anexo A y el mismo no produzca el efecto para el cual fue incorporado al fluido, YPFB CHACO no pagará por dichos materiales.

26.6 Durante un periodo de ejecución deficiente o no disponibilidad del CONTRATISTA para ejecutar los Trabajos, en caso que YPFB CHACO así disponga, el

Figura A. 1: Pozo I

SYSTEM	SERIES		GROUP	FORMATION	THICKNESS (METERS)	LITHOLOGY	DESCRIPTION	
	STAGE							
TERTIARY	NEOGENE	PLEISTOCENE	UPPER CHACO	GUANDACAY	300-1300		SS, lt rdsh bn, f-m-c gm, pebbly, congl. Clysin, dk rdsh bn.	
		MIOCENE		LOWER CHACO	TARIQUIA	500-2500		SS, lt rdsh bn, s-f gm & Clysin, dk rdsh bn, soft, sl. calc.
			OLIGOCENE		PETACA	10-120		SS, lt brnsh wht-whl, f-m-c gm, mass. G Por. Congl. lt rdsh bn, pbls. chert-lms.
CRETACEOUS	LOWER		TACURU	ICHOA	100-600		SS, med rdsh org, fm, amber qtz. large-scale cross-bedding.	
				CASTELLON	50-250		SS, wht-lt, yellowish bn, f-m, gm, Clean ss, G, Por. Clysin, lt. green, l. rdsh green.	
				TAPECUA	50-400		SS, med rdsh org, fm, amber qtz. Large-scale cross-bedding.	
				TAPECUA	20-80		Basalt, dk ppt gry/gmsh gry	
TRIASSIC	LOWER	SCYTHIAN	SUARURO	IPAGUAZU	10-130		SS, rdsh bn, f-m, gm, massive to F-G Por. Clysin, med med brnsh, med massifly, calc. G Por, whl & salt	
PERMIAN	UPPER	TATARIAN KASANIAN		VITIACUA	20-230		Lms, E, rdsh purpl-lt, bn, thin bedd, hard, cherty Med clysin & sh, Lt purple grysh ppt, Lam, calc.	
	LOWER	KONGURSKAN AHTINSKAN SUKMARSKAN ABULSKAN	CANGARI (EL-VIRA)	50-180		SS, wht-lt, red-lt, rdsh pyrite, f-m-c gm, mass abd., G Por.		
CARBONIFEROUS	UPPER	STEPHANIAN	MANDIYUTI	SAN TELMO	50-150		Clysin-Diamictite & B-l, dk rdsh, brn-l, rd, fm, blocky SS, wht-lt, rd-yellowish bn, f-m, gm, mass., G Por.	
				ESCARPMENT	400-800		SS, yellowish wht, f-l, rdsh-bn, f-m-c gm, mass, sl abd. SS-siltstn, lt, rdsh bn, SS-lt, red-lt, yellowish red, f-m-c gm, mass, blk, sl abd, Congl. at base, G Por.	
		WESTPHALIAN	MACHARETI	TAIGUATI	30-130		Clysin & diamictite, red-dk, rdsh bn/ brnsh gry, mass.	
				CHORRO	50-250		SS, lt, red/yellowish red to wht, f-m-c gm, mass, G Por.	
		LOWER			YARUA	50-600		Diamictite, lt-dk, gry, ss lenses, lt, gry-whl, f-m-c gm.
					ITACUAMI (T-2)	20-200		Clysin, B-l & Diamictite, dk, gm/black to brnsh gry.
					TUPAMBI	20-150		SS, pinkish wht/yellowish wht, f-m-c gm, mass, frst, G Por.
DEVONIAN	UPPER	TOURNAISIAN		ITACUA (SALPESQUE)	10-80		Clysin & Diamictite, ss lenses, purple redsh	
		FAMENNIAN		LOURI	50-300		B-l, lt gry, fm, fss, brn, med SS, lt, gry, f-m gm, w. str, slatp- abang, mass thin bedd, F-G Por.	
FRASNIAN								

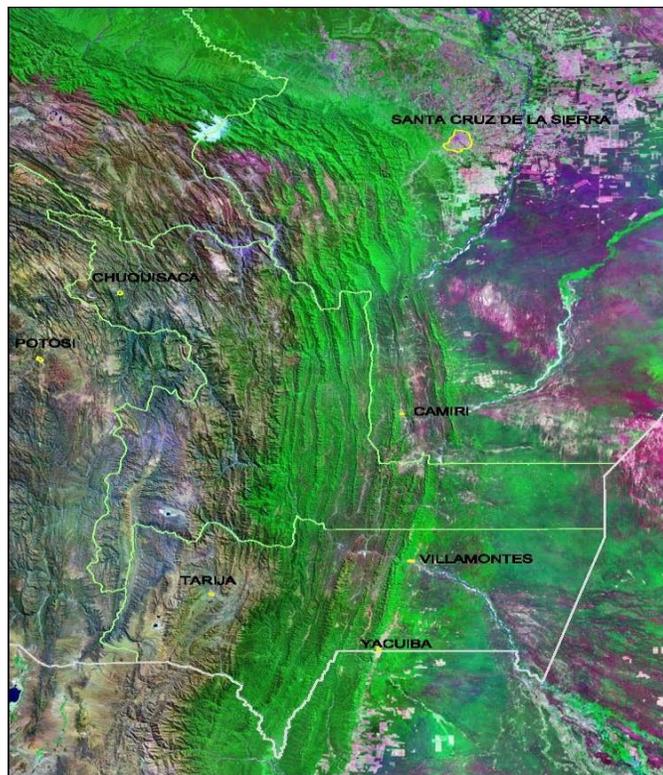
Fuente: Datos Sub Andino, YPFB CHACO, 2021

Figura A. 2: Afloramiento del Reservorio Huamampampa



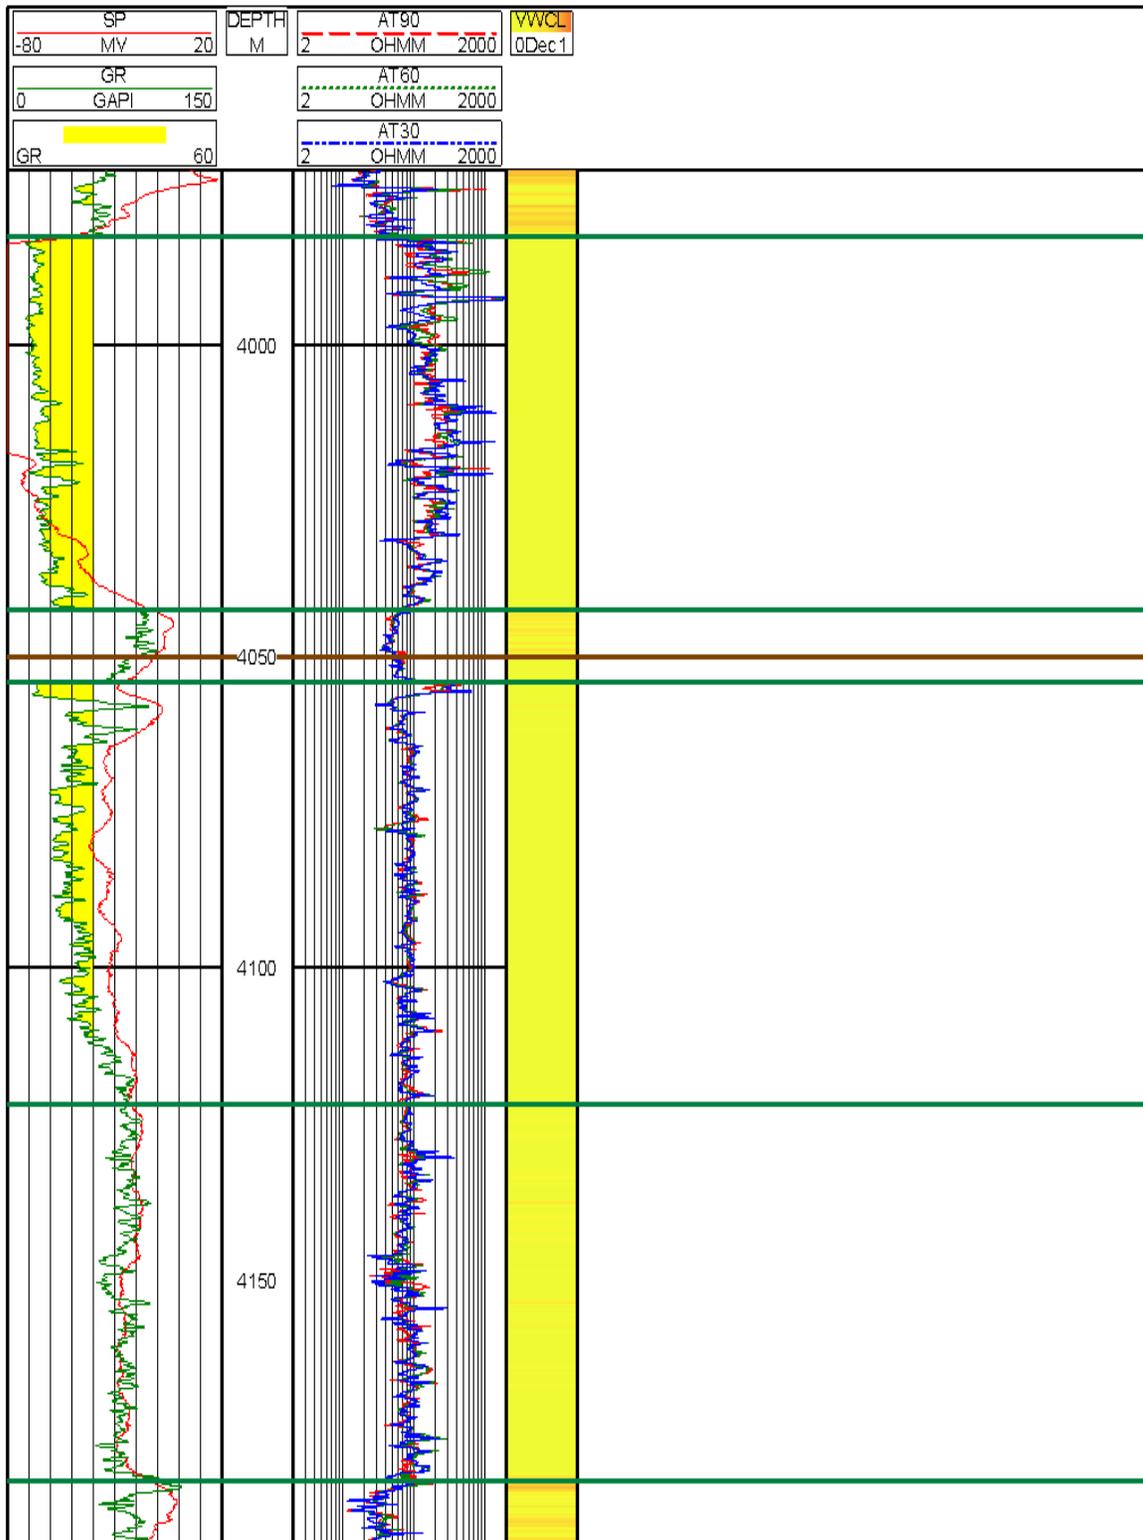
Fuente: Datos Sub Andino, YPFB CHACO, 2021

Figura A. 3: Mapa de ubicación del área de estudio



Fuente: Datos Sub Andino, YPFB CHACO, 2021

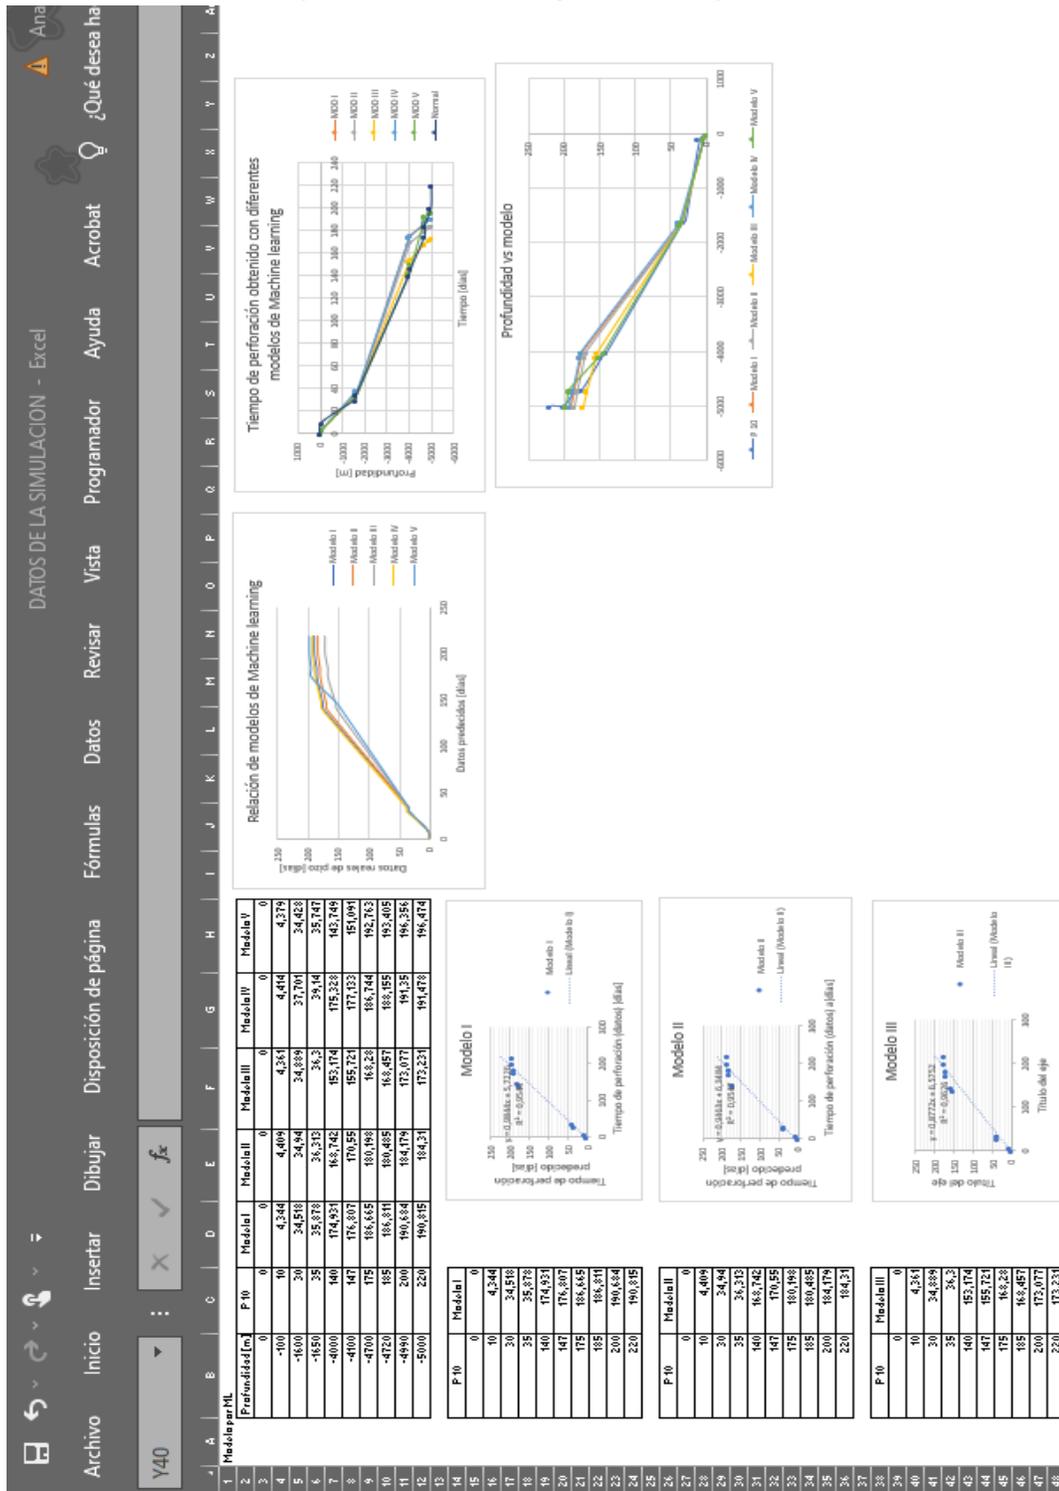
Figura A. 4: Columna estratigráfica presente en el área de estudio



Fuente: Datos Sub Andino, YPFB CHACO, 2021

ANEXOS B: DATOS DE RESPALDO DE SIMULACIÓN

Figura B. 1: Datos de respaldo de la regresión



Fuente: Elaboración propia en base a Microsoft Excel, 2023

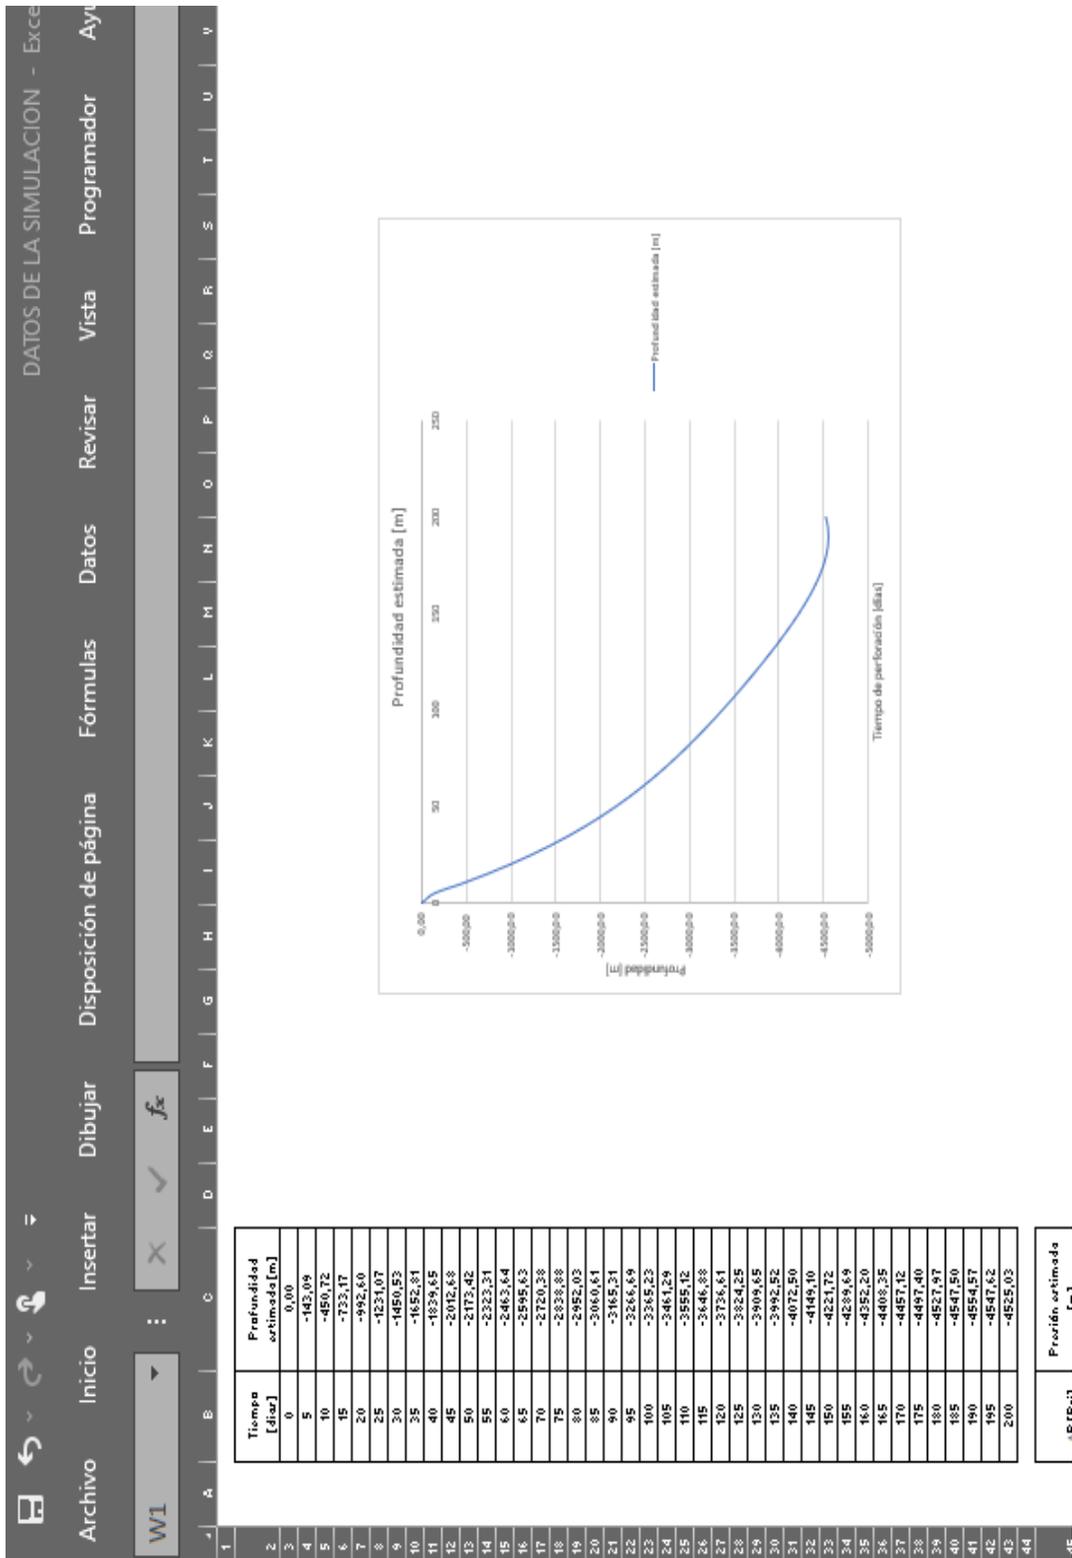


Figura B. 2: Datos de respaldo de la curva de presión

Fuente: Elaboración propia en base a Microsoft Excel, 2023

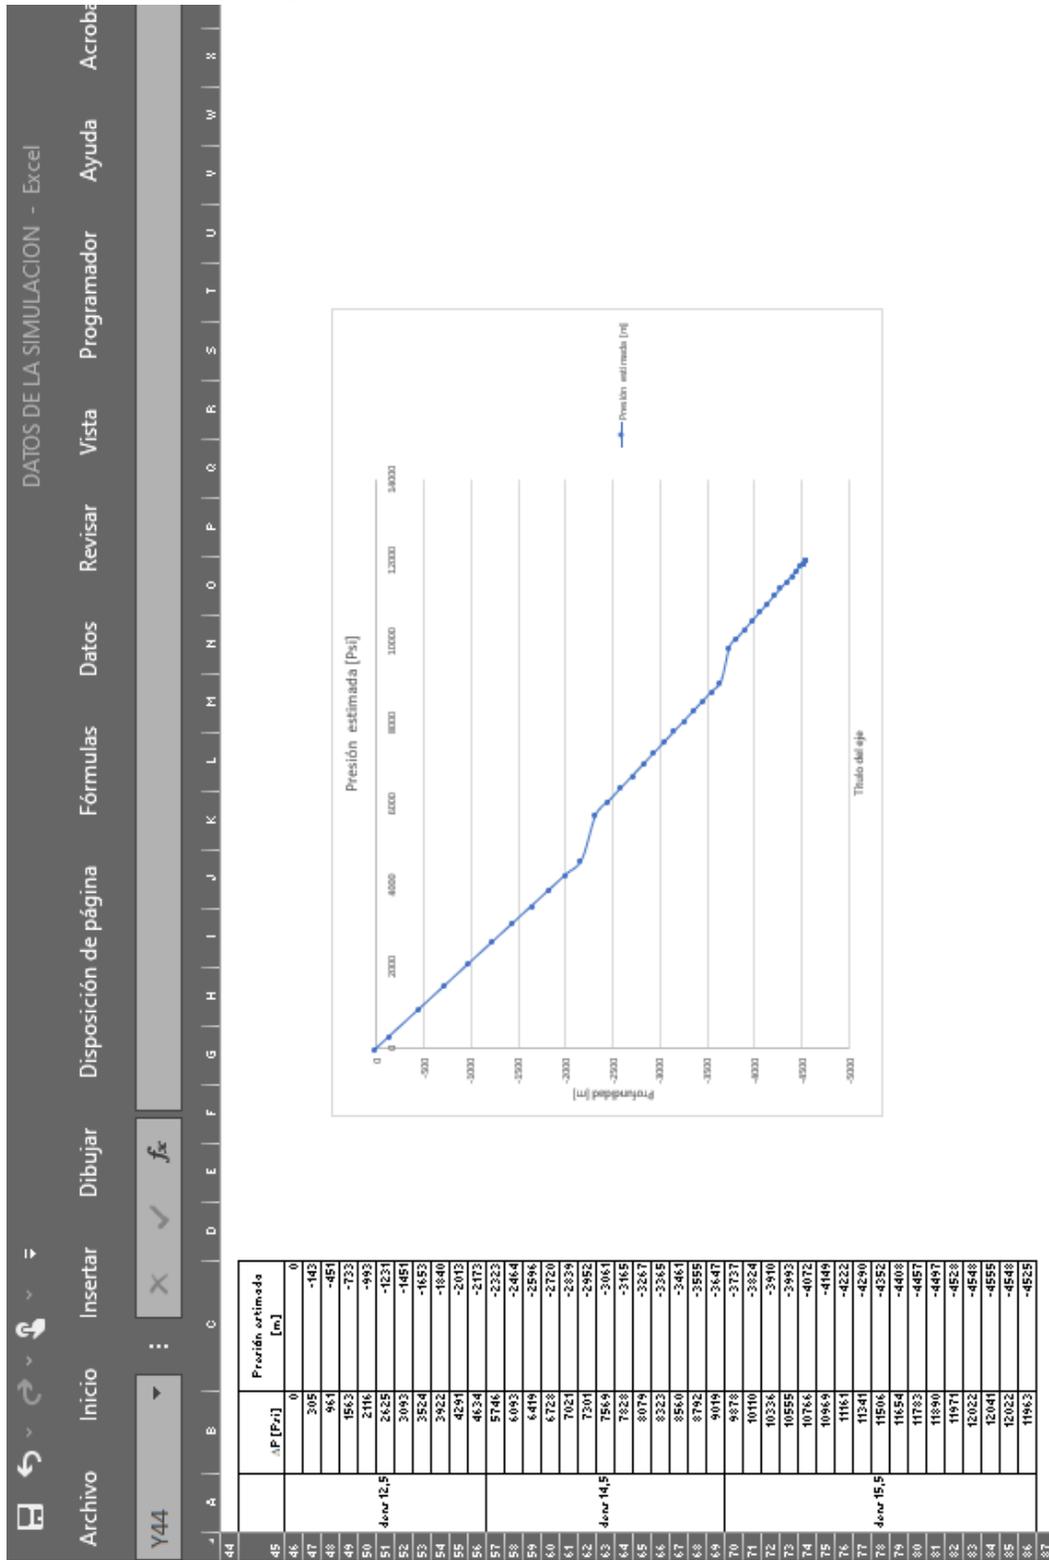
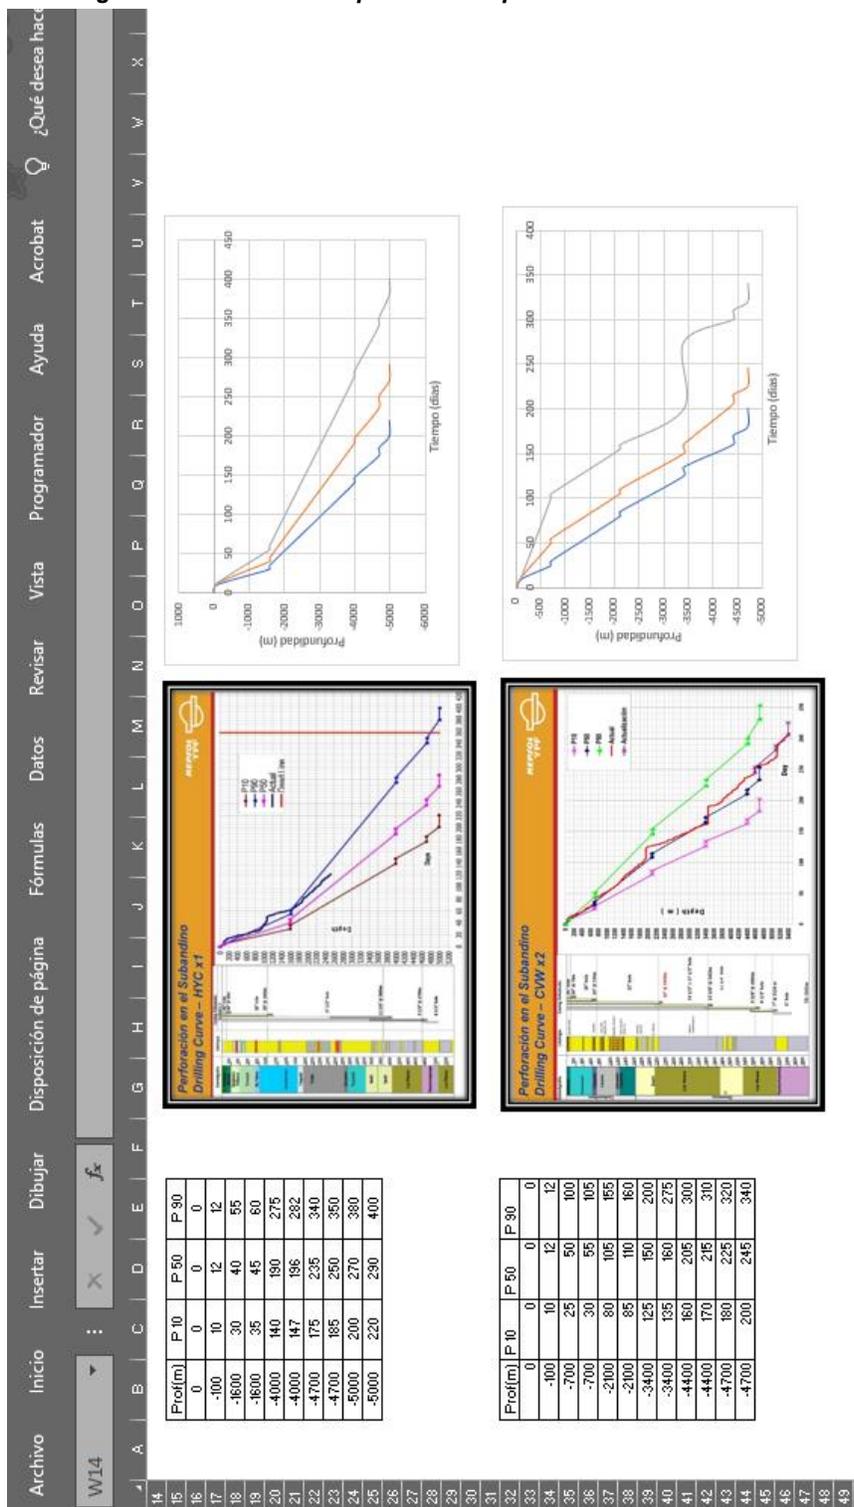


Figura B. 3: Datos de respaldo de la curva NPT

Fuente: Elaboración propia en base a Microsoft Excel, 2023

Figura B. 4: Datos de respaldo de los pozos: HYC X1 Y HCW X2

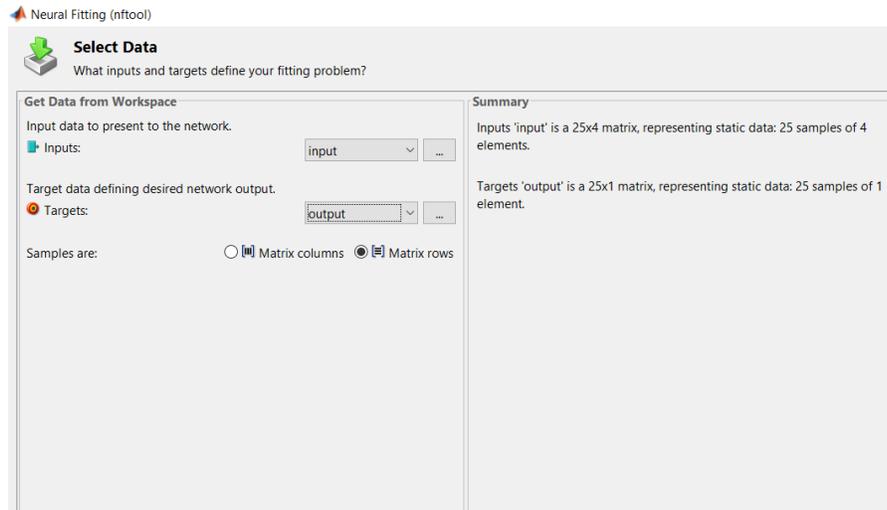


Fuente: Elaboración propia en base a Microsoft Excel, 2023

ANEXOS C: CONFIGURACIÓN DE MACHINE LEARNING EN MATLAB

Se introducen los datos del Excel para la entrada y salida de la red neuronal:

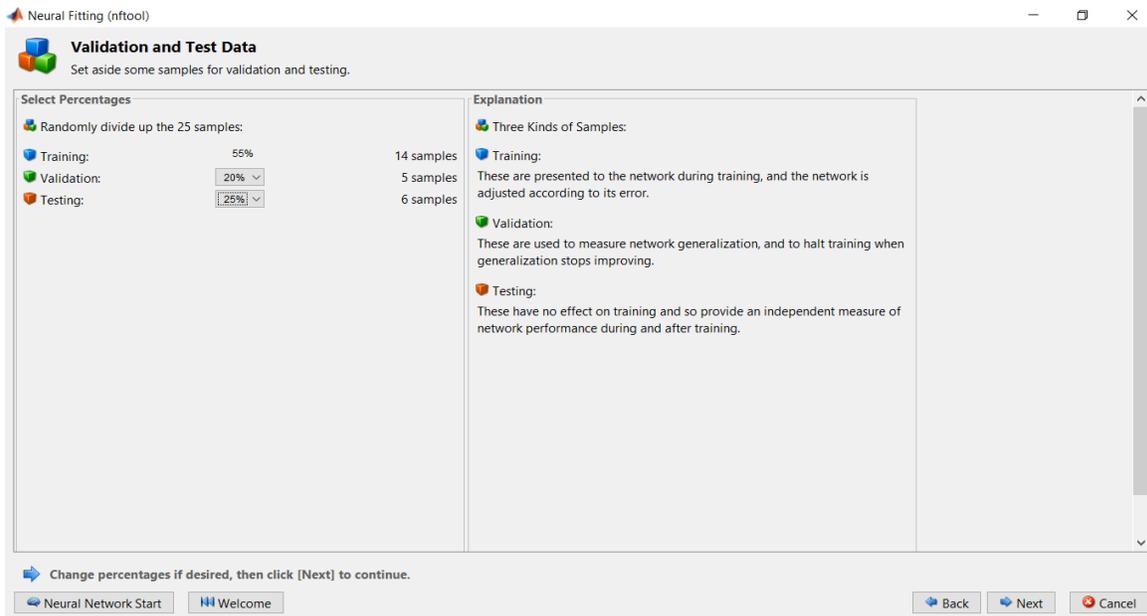
Figura C. 1: Menú de select data



Fuente: Elaboración propia en base a MATLAB, 2023

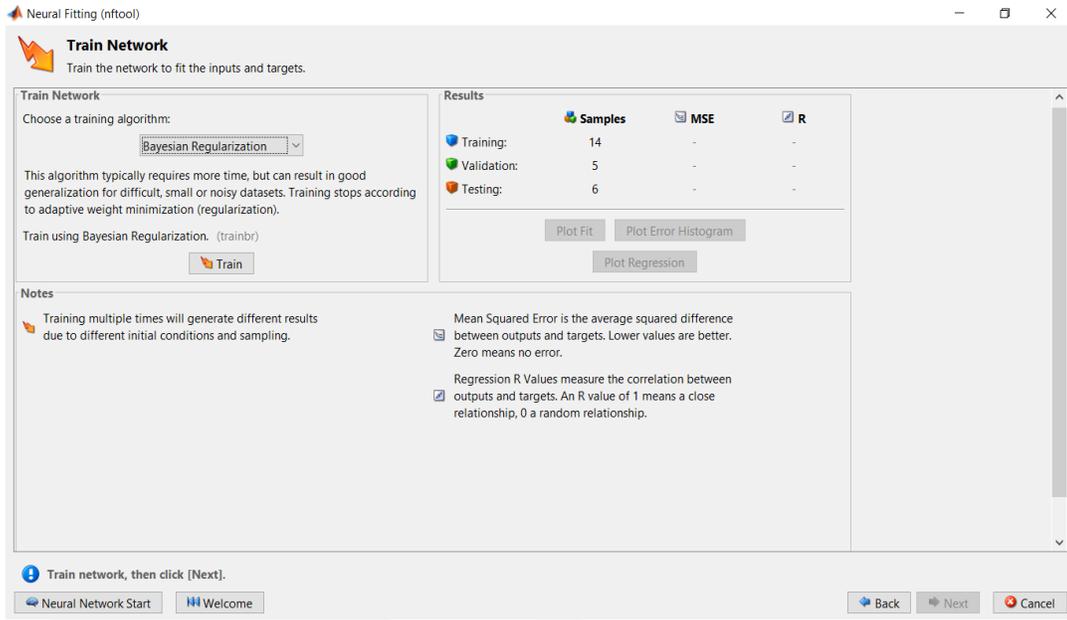
Se selecciona el entrenamiento adecuado de los datos.

Figura C. 2: Menú de Validation and test data



Fuente: Elaboración propia en base a MATLAB, 2023

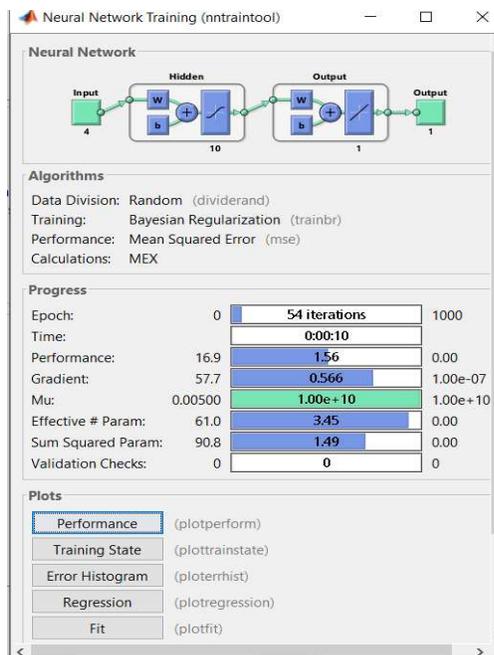
Figura C. 3: Menú de Train Network



Fuente: Elaboración propia en base a MATLAB, 2023

Obtener los datos de la simulación:

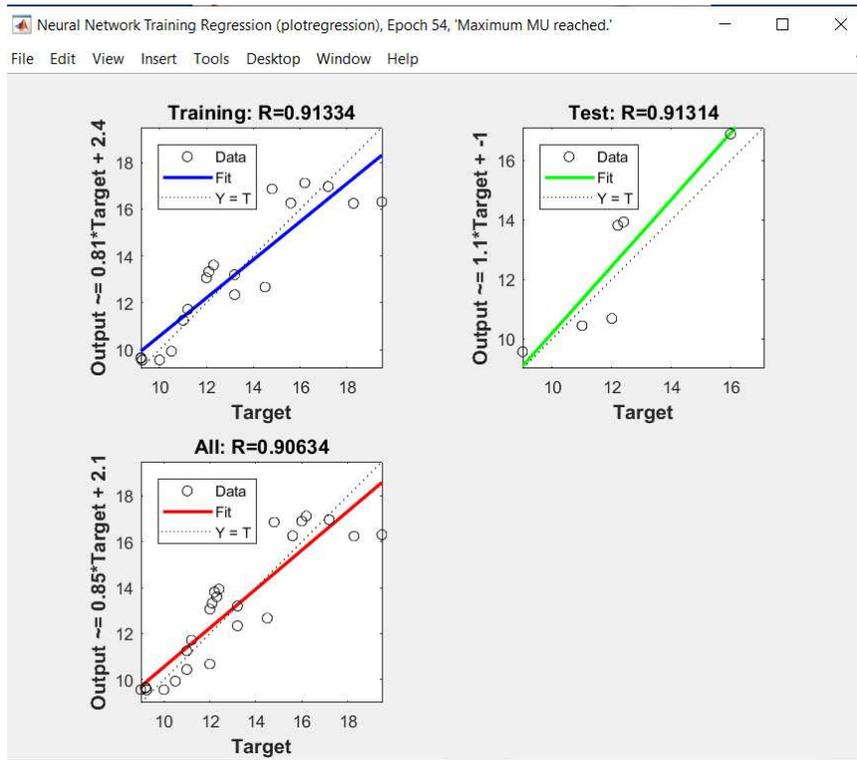
Figura C. 4: Menú de configuración de la red



Fuente: Elaboración propia en base a MATLAB, 2023

Tenemos las constantes para cada regresión y cada modelo de Machine Learning:

Figura C. 5: Ventana de resultados de iteración



Fuente: Elaboración propia en base a MATLAB, 2023

Y se predicen los datos de profundidad para cada modelo:

:

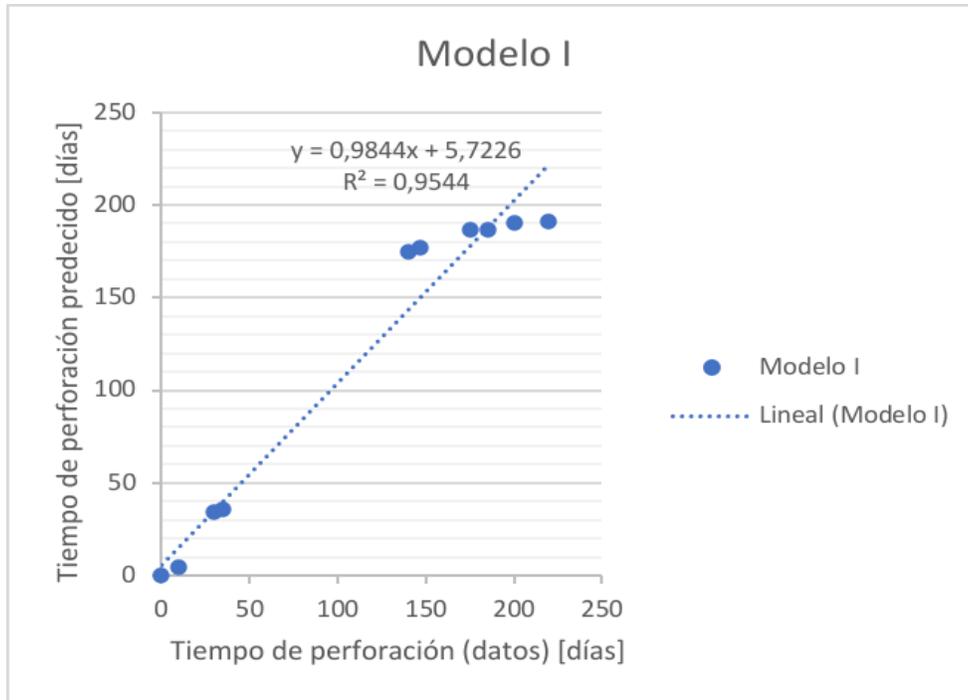
Figura C. 6: Menú de introducción de datos excel

	1	2	3	4	5	6	7	8	9	10	11
1	8.5000	9.5000	9	9.2000							
2	8.5000	9.6000	9	9.3000							
3	8.5000	9.6000	9	9.3000							
4	8.8000	9.8000	9.3000	9.5000							
5	8.8000	10	9.3000	9.7000							
6	9	11	10	10.7000							
7	9.5000	12	10.5000	11.7000							
8	9.6000	12.5000	10.6000	12.2000							

Fuente: Elaboración propia en base a MATLAB, 2023

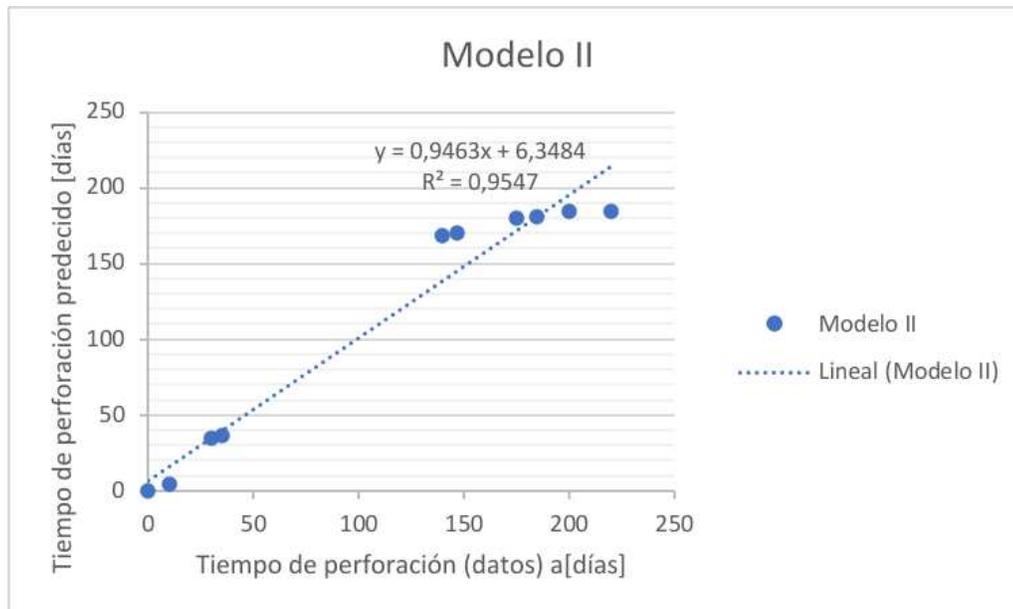
ANEXOS D: RELACIÓN DE PREDICCIÓN DE DATOS

Figura D. 1: Relación lineal del modelo I



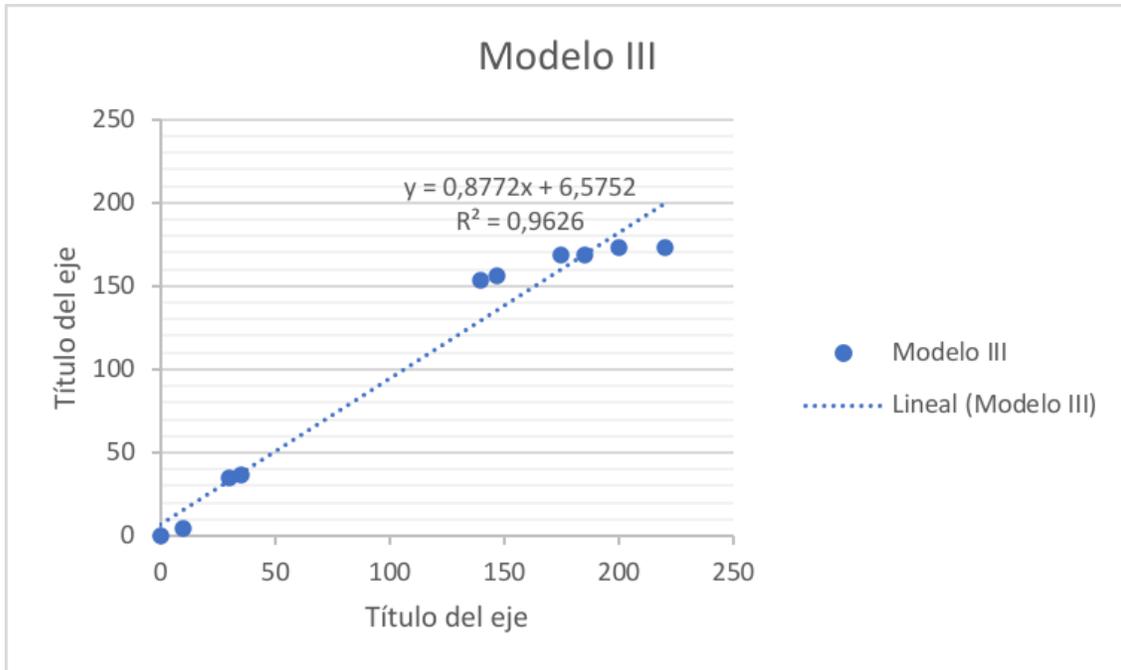
Fuente: *Elaboración propia en base a datos calculados, 2023*

Figura D. 2: Regresión del modelo II



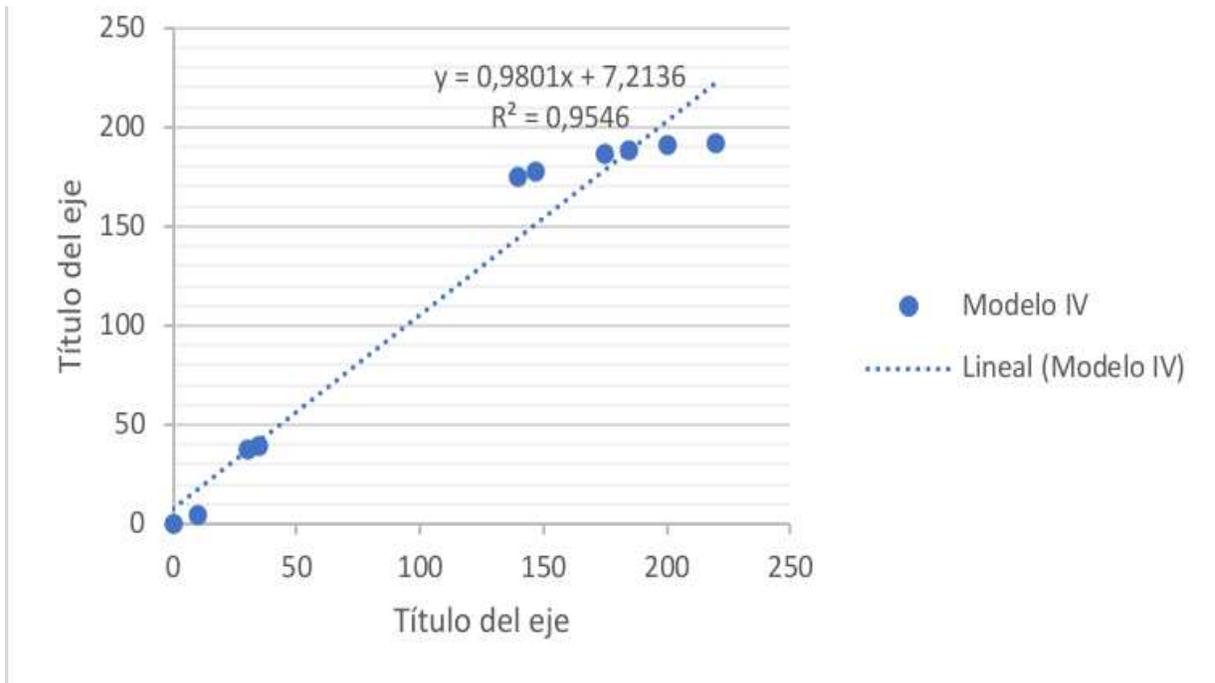
Fuente: *Elaboración propia en base a datos calculados, 2023*

Figura D. 3: Regresión del modelo III



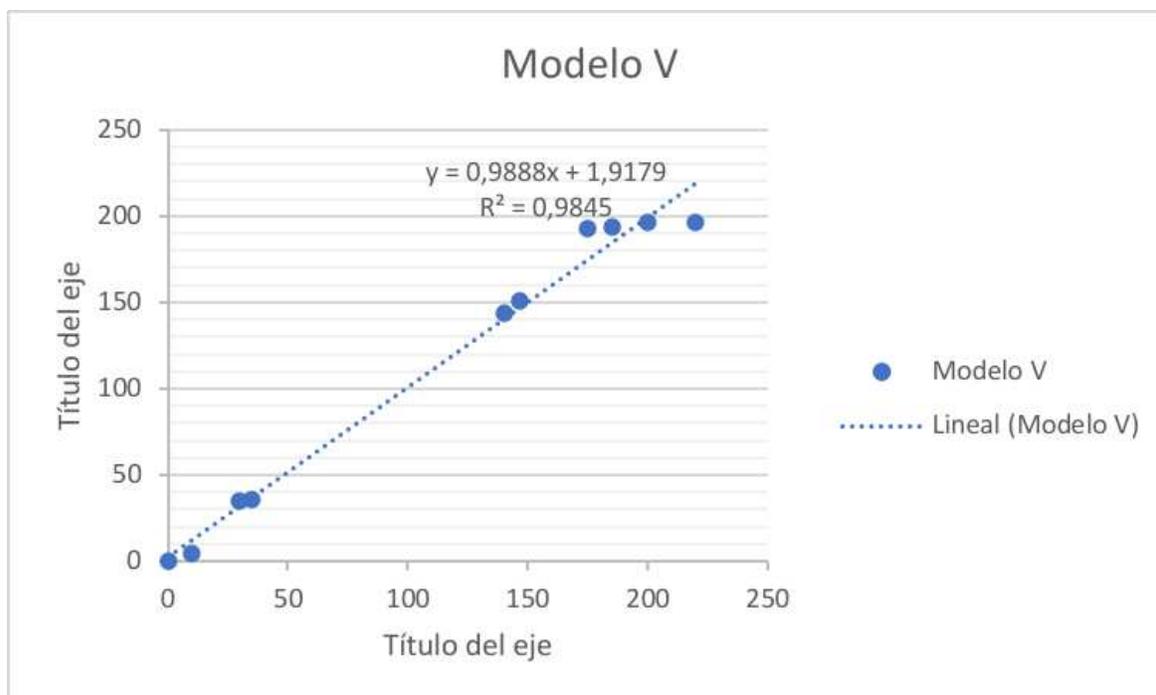
Fuente: Elaboración propia en base a datos calculados, 2023

Figura D. 4: Regresión del modelo IV



Fuente: Elaboración propia en base a datos calculados, 2023

Figura D. 5: Regresión del modelo v



Fuente: Elaboración propia en base a datos calculados, 2023

ANEXOS E: PROFUNDIDAD ESTIMADA CON EL MODELO

Tiempo [días]	Profundidad estimada [m]
0	0
5	-143,0943494
10	-450,71959
15	-733,1697994
20	-992,60344
30	-1450,52679
35	-1652,805349
40	-1839,64504
45	-2012,676249
50	-2173,42375
55	-2323,306699

60	-2463,63864
70	-2720,37559
80	-2952,03064
85	-3060,614149
90	-3165,30999
95	-3266,692399
100	-3365,23
105	-3461,285799
110	-3555,11719
115	-3646,875949
120	-3736,60824
125	-3824,254609
130	-3909,64999
140	-4072,49944
145	-4149,095299
150	-4221,72375
155	-4289,691649
160	-4352,20024
165	-4408,345149
170	-4457,11639
180	-4527,96984
190	-4554,56839
195	-4547,624949
200	-4525,03

Fuente: Elaboración propia en base a datos calculados, 2023



**DIRECCIÓN DE DERECHO DE AUTOR
Y DERECHOS CONEXOS
RESOLUCIÓN ADMINISTRATIVA NRO. 1-2423/2024
La Paz, 02 de agosto de 2024**

VISTOS:

La solicitud de Inscripción de Derecho de Autor presentada en fecha **26 de julio de 2024**, por **NERCY KAREN LIMACHI QUISPE** con **C.I. N° 9242148 LP**, con número de trámite **DA-E 300161/2024**, señala la pretensión de inscripción del Proyecto de Grado titulado: **"DETERMINACIÓN DE TIEMPOS NO PRODUCTIVOS EN LA PERFORACIÓN DE POZOS EXPLORATORIOS EN EL SUB ANDINO DE BOLIVIA, APLICANDO ALGORITMOS DE APRENDIZAJE AUTOMÁTICO BASADO EN DATOS ESTADÍSTICOS"**, cuyos datos y antecedentes se encuentran adjuntos y expresados en el Formulario de Declaración Jurada.

CONSIDERANDO:

Que, en observación al Artículo 4º del Decreto Supremo N° 27938 modificado parcialmente por el Decreto Supremo N° 28152 el *"Servicio Nacional de Propiedad Intelectual SENAPI, administra en forma desconcentrada e integral el régimen de la Propiedad Intelectual en todos sus componentes, mediante una estricta observancia de los regímenes legales de la Propiedad Intelectual, de la vigilancia de su cumplimiento y de una efectiva protección de los derechos de exclusiva referidos a la propiedad industrial, al derecho de autor y derechos conexos; constituyéndose en la oficina nacional competente respecto de los tratados internacionales y acuerdos regionales suscritos y adheridos por el país, así como de las normas y regímenes comunes que en materia de Propiedad Intelectual se han adoptado en el marco del proceso andino de integración"*.

Que, el Artículo 16º del Decreto Supremo N° 27938 establece *"Como núcleo técnico y operativo del SENAPI funcionan las Direcciones Técnicas que son las encargadas de la evaluación y procesamiento de las solicitudes de derechos de propiedad intelectual, de conformidad a los distintos regímenes legales aplicables a cada área de gestión"*. En ese marco, la Dirección de Derecho de Autor y Derechos Conexos otorga registros con carácter declarativo sobre las obras del ingenio cualquiera que sea el género o forma de expresión, sin importar el mérito literario o artístico a través de la inscripción y la difusión, en cumplimiento a la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina, Ley de Derecho de Autor N° 1322, Decreto Reglamentario N° 23907 y demás normativa vigente sobre la materia.

Que, la solicitud presentada cumple con: el Artículo 6º de la Ley N° 1322 de Derecho de Autor, el Artículo 26º inciso a) del Decreto Supremo N° 23907 Reglamento de la Ley de Derecho de Autor, y con el Artículo 4º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina.

Que, de conformidad al Artículo 18º de la Ley N° 1322 de Derecho de Autor en concordancia con el Artículo 18º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina, referentes a la duración de los Derechos Patrimoniales, los mismos establecen que: *"la duración de la protección concedida por la presente ley será para toda la vida del autor y por 50 años después de su muerte, a favor de sus herederos, legatarios y cesionarios"*

Que, se deja establecido en conformidad al Artículo 4º de la Ley N° 1322 de Derecho de Autor, y Artículo 7º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina que: *"...No son objeto de protección las ideas contenidas en las obras literarias, artísticas, o el contenido ideológico o técnico de las obras científicas ni su aprovechamiento industrial o comercial"*

Que, el artículo 4, inciso e) de la ley N° 2341 de Procedimiento Administrativo, instituye que: *"... en la relación de los particulares con la Administración Pública, se presume el principio de buena"*



fe. La confianza, la cooperación y la lealtad en la actuación de los servidores públicos y de los ciudadanos ...", por lo que se presume la buena fe de los administrados respecto a las solicitudes de registro y la declaración jurada respecto a la originalidad de la obra.

POR TANTO:

El Director de Derecho de Autor y Derechos Conexos sin ingresar en mayores consideraciones de orden legal, en ejercicio de las atribuciones conferidas.

RESUELVE:

INSCRIBIR en el Registro de Tesis, Proyectos de Grado, Monografías y Otras Similares de la Dirección de Derecho de Autor y Derechos Conexos, el Proyecto de Grado titulado: "**DETERMINACIÓN DE TIEMPOS NO PRODUCTIVOS EN LA PERFORACIÓN DE POZOS EXPLORATORIOS EN EL SUB ANDINO DE BOLIVIA, APLICANDO ALGORITMOS DE APRENDIZAJE AUTOMÁTICO BASADO EN DATOS ESTADÍSTICOS**" a favor de la autora y titular: **NERCY KAREN LIMACHI QUISPE** con **C.I. N° 9242148 LP**, quedando amparado su derecho conforme a Ley, salvando el mejor derecho que terceras personas pudieren demostrar.

Regístrese, Comuníquese y Archívese.

CASA/lm

Firmado Digitalmente por:

Servicio Nacional de Propiedad Intelectual - SENAPI
CARLOS ALBERTO SORUCO ARROYO
DIRECTOR DE DERECHO DE AUTOR Y DERECHOS CONEXOS
LA PAZ - BOLIVIA



Firma:



6pXho8Op6Mo85I

PARA LA VALIDACIÓN DEL PRESENTE DOCUMENTO INGRESAR A LA PÁGINA WEB www.senapi.gob.bo/verificacion Y COLOCAR CÓDIGO DE VERIFICACIÓN O ESCANEAR CÓDIGO QR.



Oficina Central - La Paz
Av. Montes, N° 515,
entre Esq. Uruguay y
C. Batallón Illimani.
Telfs.: 2115700
2119276 - 2119251

Oficina - Santa Cruz
Av. Uruguay, Calle
prolongación Quijarro,
N° 29, Edif. Bicentenario.
Telfs.: 3121752 - 72042936

Oficina - Cochabamba
Calle Bolívar, N° 737,
entre 16 de Julio y Antezana.
Telfs.: 4141403 - 72042957

Oficina - El Alto
Av. Juan Pablo II, N° 2560
Edif. Multicentro El Ceibo
Ltda. Piso 2, Of. 5B,
Zona 16 de Julio.
Telfs.: 2141001 - 72043029

Oficina - Chuquisaca
Calle Kilómetro 7, N° 366
casi esq. Urriagoitia,
Zona Parque Bolívar.
Telf.: 72005873

Oficina - Tarija
Av. La Paz, entre
Calles Ciro Trigo y Avaroa
Edif. Santa Clara, N° 243.
Telf.: 72015286

Oficina - Oruro
Calle 6 de Octubre, N° 5837,
entre Ayacucho
y Junín, Galería Central,
Of. 14.
Telf.: 67201288

Oficina - Potosí
Av. Villazón entre calles
Wenceslao Alba y San Alberto,
Edif. AM. Salinas N° 242,
Primer Piso, Of. 17.
Telf.: 72018160



Nercy Karen Limachi Quispe
nercykarenweareone@gmail.com
Cel.:61212572