



**UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA
CARRERA DE INGENIERÍA EN PETRÓLEO**

TEMA

**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL
PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO
VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)**

TRABAJO DE INTEGRACIÓN CURRICULAR

AUTORES:

**JEFFERSON CRISTÓBAL CHIQUITO MERO
EMILY PATRICIA GUEVARA CHÁVEZ**

TUTOR

**ROMEL ANGEL ERAZO BONE.
INGENIERO EN PETRÓLEO**

LA LIBERTAD-ECUADOR

2021

UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA
CARRERA DE INGENIERÍA EN PETRÓLEO

TEMA

SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL
PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO
VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)

TRABAJO DE INTEGRACIÓN CURRICULAR

AUTORES:

JEFFERSON CRISTÓBAL CHIQUITO MERO
EMILY PATRICIA GUEVARA CHÁVEZ

TUTOR

ROMEL ÁNGEL ERAZO BONE.
INGENIERO EN PETRÓLEO


LA LIBERTAD-ECUADOR

2021

DECLARACIÓN DE AUTORÍA

Nosotros, **Emily Guevara Chávez**, con cédula de identidad No.0951507193 y **Jefferson Chiquito Mero**, con cédula de identidad No.1311404279, declaramos bajo juramento que el presente trabajo denominado “**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)**”, es de nuestra autoría; el cual no ha sido presentado para ningún grado o calificación profesional y que hemos consultado las referencias bibliográficas incluidas en este documento.

Posteriormente, cedemos los derechos de propiedad intelectual sobre este trabajo, a la Universidad Estatal Península de Santa Elena, según lo establecido por la ley de Propiedad Intelectual, por su reglamento y por la normativa institucional vigente.



Emily Guevara Chávez

emilyguevara_12@hotmail.com

Cl. 0951507193



Jefferson Chiquito Mero

jeffersonch27@hotmail.com

Cl. 1311404279

CERTIFICACIÓN DEL TUTOR

Ing. Romel Erazo Bone, MSc.
TUTOR DE PROYECTO DE INVESTIGACIÓN
Universidad Estatal Península de Santa Elena

En mi calidad de tutor del trabajo “**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)**”, previo a la obtención del Título de Ingeniero en Petróleo elaborado por **EMILY GUEVARA CHÁVEZ** y **JEFFERSON CHIQUITO MERO**, egresados de la Carrera Ingeniería en Petróleo, de la Facultad de Ciencias de la Ingeniería de la Universidad Estatal Península de Santa Elena, me permito declarar que luego de haber orientado, estudiado y revisado, lo apruebo en todas sus partes.

**ROMEL
ANGEL
ERAZO
BONE**

Firmado digitalmente por
ROMEL ANGEL
ERAZO BONE

Fecha:
2021.08.17

16:16:59 -05'00'

Ing. Romel Erazo Bone, MSc
raerazo@upse.edu.ec
0802990838

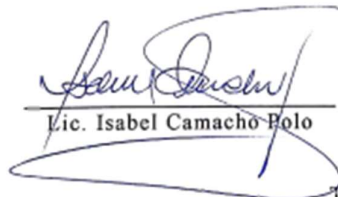
CERTIFICADO DE GRAMATOLOGÍA

CERTIFICO

Que, he revisado aspectos relacionados a la redacción, ortografía y sintaxis del trabajo de titulación, con el tema **“SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)”** elaborado por **JEFFERSON CRISTÓBAL CHIQUITO MERO** y **EMILY PATRICIA GUEVARA CHÁVEZ**, para optar por el Grado Académico de **INGENIERO EN PETRÓLEO**, de la Carrera Ingeniería en Petróleo, Facultad Ciencias de la Ingeniería de la Universidad Estatal Península de Santa Elena.

Autorizo hacer de este certificado, el uso legal que considere pertinente.

La Libertad, agosto de 2021



Lic. Isabel Camacho Polo

Teléfono: 0994416753
e-mail: isabelacamacho@hotmail.com
Reg. Senescyt 1023-11-1101534

CERTIFICADO DE ANTIPLAGIO

En calidad de tutor del trabajo de investigación para titulación del tema “**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE INTELIGENCIA ARTIFICIAL (IA)**”, elaborado por los estudiante **EMILY GUEVARA CHAVEZ** y **JEFFERSON CHIQUITO MERO**, egresados de la carrera de Ingeniería en Petróleos, de la Facultad de Ciencias de la Ingeniería, me permito declarar que una vez analizado en el sistema antiplagio URKUND, luego de haber cumplido con los requerimientos exigidos de valoración, la presente tesis, se encuentra con un 8 % de la valoración permitida.



Urkund Analysis Result

Analysed Document:	CHIQUITO.docx (D111398044)
Submitted:	8/17/2021 9:58:00 PM
Submitted By:	raerazo@upse.edu.ec
Significance:	8 %

**ROMEL
ANGEL
ERAZO
BONE**

Firmado digitalmente por
ROMEL ANGEL
ERAZO BONE

Fecha:
2021.08.17
16:17:23 -05'00'

Romel Erazo Bone
raerazo@upse.edu.ec
0802990838
TUTOR

DEDICATORIA

A **Dios**, quien con su infinito amor nos dio la sabiduría y fortaleza para seguir adelante, a **nuestros padres**, que han sido el más grande apoyo que hemos tenido, al Ing. Romel Erazo Bone, por darnos la oportunidad de realizar este trabajo bajo su asesoría, a la **Universidad Estatal Península de Santa Elena** por acogernos en sus aulas y permitir formarnos como profesionales.

TRIBUNAL DE GRADO

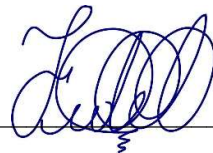
Qf. Rolando Calero Mendoza, PhD.
DIRECTOR DE LA CARRERA
DE PETRÓLEOS

ROMEL
ANGEL
ERAZO
BONE




Firmado digitalmente por
ROMEL ANGEL
ERAZO BONE
Fecha: 2021.11.26
09:26:38 -05'00'

Ing. Romel Erazo Bone, MSc
TUTOR



Ing. Fidel Chuchuca Aguilar, MSc
PROFESOR DE ÁREA



Firmado digitalmente
por ERICA
LORENZO
GARCIA

Lcda. Erica Lorenzo García, PhD.
DOCENTE Y SECRETARÍA DE LA UIC

CONTENIDO

pág.

DECLARACIÓN DE AUTORÍA.....	iii
CERTIFICACIÓN DEL TUTOR	iv
CERTIFICADO DE GRAMATOLOGÍA	v
CERTIFICADO DE ANTIPLAGIO.....	vi
DEDICATORIA	vii
TRIBUNAL DE GRADO	viii
ÍNDICE DE GRÁFICOS	xi
ÍNDICE DE TABLAS	xiv
ÍNDICE DE ECUACIONES.....	xvi
RESUMEN.....	xviii
ABSTRACT	xix
INTRODUCCIÓN	1
CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA	2
1.1 DESCRIPCIÓN DEL TEMA.....	2
1.2 ANTECEDENTES.....	3
1.3 PLANTEAMIENTO DEL PROBLEMA.....	4
1.4 JUSTIFICACIÓN.....	5
1.5 OBJETIVOS	6
1.5.1 Objetivo general.....	6
1.5.2 Objetivos específicos.....	6
1.6 ALCANCE DE LA PROPUESTA.....	6
1.7 HIPÓTESIS DE TRABAJO.....	7
1.8 VARIABLES	7
1.8.1 Variable independiente.....	7
1.8.2 Variables dependientes.....	7
CAPÍTULO II: MARCO TEÓRICO	8
2.1 DESCRIPCIÓN DEL CAMPO GGV	8
2.1.1 Ubicación del campo.....	8
2.1.2 Historia de explotación.....	9
2.1.3 Historial de producción	10
2.1.4 Producción acumulada de petróleo (Np) en cada sección.....	10
2.1.5 Reservas del campo.....	12

2.1.6	Propiedades de los fluidos.....	13
2.1.7	Producción diaria.....	14
2.1.8	Estructura geológica.....	15
2.1.9	Litología del campo.....	15
2.2	ESTADO ACTUAL DE LOS POZOS EN LA SECCIÓN 66.....	19
2.3	DESCRIPCIÓN DE LOS SISTEMAS DE LEVANTAMIENTO ARTIFICIAL.....	25
2.3.1	Bombeo mecánico.....	25
2.3.2	Pistoneo o Swab.....	31
2.3.3	Herramienta local.....	37
2.4	APRENDIZAJE POR COMPUTADOR.....	40
2.4.1	Descripción.....	40
2.4.2	Historia.....	42
2.4.3	Machine learning.....	43
2.5	HERRAMIENTA PARA VIABILIDAD.....	53
2.5.1	Valor actual neto.....	53
CAPÍTULO III: METODOLOGÍA.....		54
3.1	METODOLOGÍA DE LA INVESTIGACIÓN.....	54
3.1.1	Tipo de investigación.....	54
3.1.2	Recopilación de datos e información.....	54
3.1.3	Población y muestra.....	55
3.1.4	Procesamiento de Información.....	55
3.2	METODOLOGÍA DE ANÁLISIS.....	55
3.2.1	Criterios para la selección del SLA óptimo a implementar en la sección 66.....	55
3.3	ESTRUCTURACIÓN DE ALGORITMO.....	61
3.3.1	Comprobación del sla seleccionado utilizando dos variables.....	73
CAPÍTULO IV: ANÁLISIS Y DISCUSIÓN DE RESULTADOS.....		76
4.1	MÉTODO DE SLA SELECCIONADO POR EL ALGORITMO DE ÁRBOL DE DECISIÓN.....	76
4.2	ANÁLISIS ECONÓMICO.....	84
4.2.1	Desarrollo del análisis económico.....	85
CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES.....		105
5.1	CONCLUSIONES.....	105
5.2	RECOMENDACIONES.....	107
REFERENCIAS BIBLIOGRÁFICAS.....		108

ÍNDICE DE GRÁFICOS

pág.

Figura 1. Ubicación del campo GGV	9
Figura 2. Pozo Anc-0001	10
Figura 3. Producción acumulada de petróleo (Np) del campo GGV	11
Figura 4. Corte geológico del campo GGV	17
Figura 5. Columna estratigráfica del campo GGV	18
Figura 6. Porcentual de pozos según su estado	19
Figura 7. Porcentual de SLA usados en la sección 66.....	20
Figura 8. Numero de pozos que producen de cada formación productora	22
Figura 9. Reserva de las formaciones productoras	22
Figura 10. Producción diaria de pozos que operan con BM.....	23
Figura 11. Producción diaria de pozos que operan con HL.....	24
Figura 12. Producción diaria de pozos que operan con SW	24
Figura 13. Unidad de BM utilizada en el campo GGV	25
Figura 14. SLA Pistoneo o SW	31
Figura 15. SLA por HL	37
Figura 16. IA y categorías relacionadas	41
Figura 17. Estatua de pizarra de Alan Turing en Bletchley Park	43
Figura 18. Machine learning subcampo de la IA	44
Figura 19. Los Tipos de Aprendizaje Automático	45
Figura 20. Flujo de trabajo de Machine Learning	47
Figura 21. Los árboles de decisión están formados por nodos.....	50
Figura 22. Gastos mensuales que genera cada SLA en un pozo	61
Figura 23. Área de trabajo en notebook	62
Figura 24. Importar librería	62
Figura 25. Lectura del archivo xlsx.....	63
Figura 26. Visualización y modificación del formato de variables.....	63
Figura 27. Tipo de data.....	64
Figura 28. Estadística descriptiva del dataframe	64
Figura 29. Agrupar dataframe	64
Figura 30. Contar celdas de entradas nulas	65
Figura 31. Mostrar el número de datos respecto a las variables analizadas	65
Figura 32. Línea de código para graficar producción acumulada	65
Figura 33. Producción acumulada en el período 2016-2020.....	66
Figura 34. Línea de código para graficar los gastos totales.....	66

Figura 35. Gastos totales generados en el período 2016-2020	66
Figura 36. Línea de código para graficar la producción total.....	67
Figura 37. Producción en el período 2016- 2020 de las formaciones	67
Figura 38. Pozos productores con su respectiva gravedad API.....	68
Figura 39. Método Pearson del dataframe.....	68
Figura 40. Mapa de calor del método Pearson	69
Figura 41. Data cleaning.....	69
Figura 42. Aseguramiento de calidad	70
Figura 43. Predicción del algoritmo árbol de decisión.....	70
Figura 44. Target de SLA	71
Figura 45. Etiquetar variables.....	71
Figura 46. Entrenamiento del algoritmo.....	71
Figura 47. Creación del algoritmo árbol de decisión.....	72
Figura 48. Predicción del algoritmo árbol de decisión.....	72
Figura 49. Precisión del algoritmo árbol de decisión	72
Figura 50. Matriz de confusión.....	73
Figura 51. Árbol de decisión	73
Figura 52. Establecer las dos variables.....	73
Figura 53. Variables seleccionadas	73
Figura 54. Etiquetar las dos variables.....	74
Figura 55. Entrenamiento del algoritmo con dos variables	74
Figura 56. Creación del árbol de decisión con dos variables	74
Figura 57. Predicción del árbol de decisión con dos variables.....	74
Figura 58. Precisión del algoritmo árbol de decisión con dos variables	75
Figura 59. Línea para generar el código del árbol de decisión con dos variables	75
Figura 60. Árbol de decisión	78
Figura 61. Nodos de producción acumulada, ciclos y gasto total	79
Figura 62. Nodos de ciclos y gravedad API.....	80
Figura 63. Nodos de gravedad API y ciclos	81
Figura 64. Nodos de ciclos y gasto total.....	81
Figura 65. Nodo de gasto total	82
Figura 66. Nodos de gasto total y ciclos.....	83
Figura 67. Nodo de ciclos.....	83
Figura 68. Árbol de decisión con dos variables.....	84
Figura 69. Gráfico de flujo de caja sin implementar el proyecto	94
Figura 70. Gráfico de flujo de caja con la implementación proyecto.....	94
Figura 71. Gráfico comparativo de flujos de caja	95
Figura 72. Gráfico de flujo de caja sin implementar el proyecto	103
Figura 73. Gráfico de flujo de caja con la implementación proyecto.....	103
Figura 74. Gráfico comparativo de flujos de caja	104
Figura A 1. Herramienta ejecutar de Windows.....	113
Figura A 2. Procedimiento para instalar "jupyter"	113
Figura A 3. Instalación del entorno de trabajo "jupyter".....	114
Figura A 4. Instalación de la librería "pandas".....	114
Figura A 5. Instalación de la Librería "sklearn"	115
Figura A 6. Instalación de la Librería "matplotlib"	115
Figura A 7. Comando para abrir el entorno de trabajo "jupyter notebook"	116

Figura A 8. Librerías complementarias	116
Figura A 9. Pestaña correspondiente al home de jupyter	117
Figura A 10. Crear un notebook	117

ÍNDICE DE TABLAS

pág.

Tabla 1. Coordenadas graficas campo GGV	8
Tabla 2. Coordenadas UTM campo GGV	8
Tabla 3. Producción acumulada de petróleo del campo GGV	11
Tabla 4. Reservas del campo GGV	13
Tabla 5. Gravedad API promedio de las formaciones productoras	14
Tabla 6. Producción y estado de los pozos del campo GGV	14
Tabla 7. Estado de pozos Campo GGV “sección 66”	19
Tabla 8. Pozos productores del campo GGV "sección 66"	20
Tabla 9. Profundidad de los pozos que operan con SW o Pistoneo	56
Tabla 10. Profundidad de los pozos que operan con BM	56
Tabla 11. Profundidad de los pozos que operan con HL.....	56
Tabla 12. Clasificación del petróleo según los grados API.....	57
Tabla 13: Grados API del fluido de los pozos que producen con SW o Pistoneo	57
Tabla 14: Grados API del fluido de los pozos que producen con BM	58
Tabla 15: Grados API del fluido de los pozos que producen con HL	58
Tabla 16. Producción promedio diaria de los pozos que operan por SW	59
Tabla 17. Producción promedio diaria de los pozos que operan por BM	59
Tabla 18. Producción promedio diaria de los pozos que operan por HL	59
Tabla 19. Gasto promedio mensual del SLA SW (por cada pozo)	60
Tabla 20. Gasto promedio mensual del SLA BM (por cada pozo)	60
Tabla 21. Gasto promedio mensual del SLA HL (por cada pozo)	61
Tabla 22. Inversión requerida para el cambio del SLA SW a BM.....	85
Tabla 23. Inversión requerida para el cambio del SLA HL a BM.....	86
Tabla 24, Flujo de caja sin proyecto con el SLA SW.....	88
Tabla 25. Flujo de caja con proyecto para el SLA SW	92
Tabla 26. Flujo de caja sin proyecto para el SLA HL	97
Tabla 27. Flujo de caja con proyecto para el SLA HL	101
Tabla B 1. Producción y gastos de los pozos productores	118
Tabla C 1. Ingresos por producción mensual del SLA SW.....	119
Tabla C 2. Ingresos por producción mensual al implementar BM por SW	120
Tabla C 3. Ingresos por producción mensual del SLA HL	121
Tabla C 4. Ingresos por producción mensual al implementar BM por HL	122

Tabla D 1. Producción total de los pozos con SLA HL 2016	123
Tabla D 2. Producción total de los pozos con SLA HL 2017	124
Tabla D 3. Producción total de los pozos con SLA HL 2018	125
Tabla D 4. Producción total de los pozos con SLA HL 2019	126
Tabla D 5. Producción total de los pozos con SLA HL 2020	127
Tabla E 1. Producción total de los pozos con SLA SW 2016	128
Tabla E 2. Producción total de los pozos con SLA SW 2017	128
Tabla E 3. Producción total de los pozos con SLA SW 2018	129
Tabla E 4. Producción total de los pozos con SLA SW 2019	129
Tabla E 5. Producción total de los pozos con SLA SW 2020	130
Tabla F 1. Producción total de los pozos con SLA BM 2016.	130
Tabla F 2. Producción total de los pozos con SLA BM 2017.	131
Tabla F 3. Producción total de los pozos con SLA BM 2018.	131
Tabla F 4. Producción total de los pozos con SLA BM 2019	132
Tabla F 5. Producción total de los pozos con SLA BM 2020	132
Tabla G 1. Producción acumulada anual	133

ÍNDICE DE ECUACIONES

pág.

(1) Formula gravedad API.....	14
(2) El error de clasificación	50
(3) Índice Gini	51
(4) Entropía.....	51
(5) Valor actual neto	53
(6) Pronostico de ingresos	85
(7) Flujo de caja sin proyecto	86
(8) Flujo de caja con proyecto	90
(9) Flujo de caja sin proyecto	96
(10) Flujo de caja con proyecto	99

ABREVIATURAS

GGV	Gustavo Galindo Velasco
SLA	Sistema Levantamiento Artificial
BM	Bombeo Mecánico
SW	Swab
HL	Herramienta Local
IA	Inteligencia Artificial
AT	Atlanta
CPB	Clay Pebble Bed
PB	Passage Beg
ST	Santo Tomas
BSW	Contenido de agua y sedimentos

**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA
SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE
INTELIGENCIA ARTIFICIAL**

RESUMEN

Esta investigación tiene como objetivo evaluar los sistemas a través de la técnica machine learning con el propósito de seleccionar un único SLA óptimo de la sección 66 del campo Gustavo Galindo Velasco, para aumentar la producción, mejorar las operaciones, reducir los riesgos de pérdidas y valorar la viabilidad y factibilidad de la propuesta. El presente trabajo se basa en una investigación descriptiva, cuantitativa y comparativa de los diferentes métodos de levantamiento artificial con los que se está produciendo en el campo GGV “sección 66”. La investigación teórica es necesaria para la recopilación de información sobre los SLA por BM, HL y Pistoneo o SW. La predicción del algoritmo árbol de decisión da como resultado que el sistema de levantamiento artificial óptimo a implementar en toda la sección 66 es bombeo mecánico, porque los pozos que operan con este sistema obtuvieron una mayor tasa de producción durante el periodo 2016-2020 en comparación a los pozos que producen con otros sistemas de levantamiento artificial, y a su vez generaron menor gasto de operación y mantenimiento debido a que las intervenciones que se realizan en los pozos son de bajo costo, además se economiza dinero en combustible, grasas, lubricantes y repuestos.

**PALABRAS CLAVE: MACHINE LEARNING/SISTEMA DE
LEVANTAMIENTO ARTIFICIAL/ALGORITMO/ ÁRBOL DE DECISIÓN**

**SELECCIÓN DEL SISTEMA DE LEVANTAMIENTO ARTIFICIAL PARA LA
SECCIÓN 66 DEL CAMPO GUSTAVO GALINDO VELASCO MEDIANTE
INTELIGENCIA ARTIFICIAL**

ABSTRACT

This research aims to evaluate the systems through the machine learning technique in order to select a single optimal SLA from section 66 of the Gustavo Galindo Velasco field, to increase production, improve operations, reduce the risks of losses and value the feasibility and feasibility of the proposal. The present work is based on a descriptive, quantitative and comparative investigation of the different artificial lift methods with which it is taking place in the GGV field "section 66". Theoretical research is necessary for the collection of information on SLAs by BM, HL and Pistoneo or SW. The decision tree algorithm prediction results in the optimal artificial lift system to be implemented throughout section 66 is mechanical pumping, because the wells that operate with this system obtained a higher production rate during the 2016-2020 period compared to the wells that produce with other artificial lift systems, and in turn generated lower operating and maintenance expenses due to the fact that the interventions carried out in the wells are low cost, in addition to saving money on fuel, greases, lubricants and spare parts .

**KEYWORDS: MACHINE LEARNING/ARTIFICIAL LIFT SYSTEMS /
ALGORITHM /DECISION TREE**

INTRODUCCIÓN

En la actualidad la industria del petróleo busca mejoras continuas para maximizar la tasa de producción y minimizar los costos de operación, al iniciar la etapa de explotación de un yacimiento la producción del petróleo se obtiene por flujo natural, sin embargo, a medida que declina la presión del yacimiento la producción disminuye lo que implica suministrar energía externa para levantar el fluido a superficie, para aquello se utiliza en los pozos un sistema de levantamiento artificial que permita seguir produciendo eficientemente, el mismo que se seleccionará después de realizar un estudio de factibilidad.

La selección del mejor sistema puede resultar complejo para el personal operativo ya sea por condiciones de operación, eficiencia, capacidad de producción y costo de inversión, para aquello la Inteligencia Artificial (IA) asiste a los humanos en la toma de decisiones por medio de máquinas con la finalidad de que aprendan de la experiencia, se ajusten a nuevos contextos y actúen de forma similar a como lo haría un humano. El objetivo de este trabajo es mediante la técnica machine learning seleccionar un único SLA en la sección 66 del Campo GGV.

Este estudio contiene los siguientes capítulos: El **capítulo 1** contiene el planteamiento y antecedentes de la investigación. En el **capítulo 2** se describe las generalidades del campo, identificación de los sistemas de levantamiento artificial, su funcionamiento y una introducción de IA específicamente de la técnica machine learning. En el **capítulo 3** se describe la metodología del proyecto en el cual se utiliza el algoritmo árbol de decisión, cuyo funcionamiento es predecir por medio de la selección de criterios de un dataframe el sistema óptimo a implementar en el área de estudio. En el **capítulo 4**, con base a los resultados obtenidos por parte del algoritmo el sistema de levantamiento artificial a implementar es bombeo mecánico, permitiendo levantar una óptima cantidad de fluido a una menor inversión lo que resulta factible el cambio de método de extracción. En el **capítulo 5** se presentan las conclusiones y recomendaciones para este trabajo de investigación.

CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA

1.1 DESCRIPCIÓN DEL TEMA

La industria petrolera emplea métodos tradicionales de control de procesos, los cuales están sujetos a tener grandes márgenes de error humano, además estos procesos demandan mucho tiempo. Sin embargo, con la aplicación de la técnica machine learning basada en la creación de algoritmos que aprenden iterativamente dentro de grandes conjuntos de datos (conocido como dataset) permiten a una máquina o software identificar patrones de comportamiento entre millones de datos, realizando estimaciones con un alto grado de precisión de manera rápida y eficiente.

Esta investigación busca evaluar los sistemas a través de la técnica machine learning con el propósito de seleccionar un único SLA óptimo de la sección 66 del campo GGV, para aumentar la producción, mejorar las operaciones, reducir los riesgos de pérdidas y valorar la viabilidad y factibilidad de la propuesta del proyecto de tesis.

Un algoritmo de machine learning determina el SLA óptimo para toda la sección 66, con un análisis crítico comparativo de las variables; condiciones de los pozos, historial de producción, historial de Workover, tipos de fluido en función de su gravedad, costos operativos y mantenimiento.

1.2 ANTECEDENTES

En febrero del 2021 se desarrolló un modelo machine learning para la selección del mejor mecanismo de control de arena entre los mecanismos *zeta flow* y *high rate water pack* en un campo de los llanos orientales de Colombia, el cual consiste en un modelo predictivo basado en el lenguaje de programación Python, que interpreta los parámetros operativos y antecedentes de trabajo y los asimila como entrenamiento para llegar a la predicción más acertada logrando con este modelo la reducción de producción de arena (Martínez, 2021).

En enero del 2019 un estudio demuestra que el método de Machine Learning supervisado se puede aplicar para mejorar el proceso de selección de levantamiento Artificial. Este enfoque puede minimizar el costo del ciclo de vida de los pozos, mediante el uso de machine Learning. Y consiste en que la información se agrupa en datos estructurados y este conjunto de datos se procesa previamente para determinar los pozos "buenos" y "malos" en función de su costo de ciclo de vida, luego se utiliza para capacitar y validar los modelos de clasificación. Se adopta el modelo más simple y preciso para la selección futura del levantamiento artificial y la evaluación del desempeño de los pozos actuales (Ounsaku, Thum, & Wiwat , 2019).

En el 2017 un estudio clasificó, organizó y comparó métodos de la IA (Redes Neuronales, Lógica Difusa, Algoritmos Genéticos, Sistemas Neuro-Fuzzy) para el reconocimiento de patrones en la detección y diagnóstico de fallas, específicamente en el área de equipos de levantamiento mecánico. Se demostró que con la IA se busca agilizar y poseer grandes niveles de precisión en la identificación de las diferentes fallas en los equipos de levantamiento mecánico, mediante redes neuronales, lo que conlleva la importancia de que es económico, fácil de implementar, el más práctico y es más asertivo en el diagnóstico de fallas en la bomba de fondo, logrando una óptima producción y disminución de los costos de mantenimiento y operación (Garavito Arena , 2017).

En San Tome-Venezuela se planteó la implementación de un sistema supervisor inteligente para procesos de producción de petróleo, el cual consistió en un módulo de detección y diagnóstico de fallas, basado en redes neuronales artificiales, que permite detectar las fallas más comunes en el actuador y el sensor del sistema de control en lazo

cerrado y en cualquier otro sensor de importancia para la planta. Dicha propuesta fue dirigida a sistemas de producción continua, como el proceso de extracción y tratamiento del crudo (Colina, 2014).

El 25 de febrero del 2011, una investigación sobre técnicas computacionales en procesos de perforación, basados en IA, demostró que el tratamiento digital de imágenes de IA sirve para obtener mejores resultados cuando se desarrolla un sistema automático de perforación para el control de plataformas (Galvis, 2011).

En 2009, en Caracas-Venezuela, se presentó una metodología de IA basada en un sistema de pronóstico, que determinó la conveniencia de aplicar una solución con propiedades tensoactivas en pozos de petróleo, analizando variables como características del crudo y características geológicas, con el objetivo de incrementar su producción se procesaron los datos de 12 pozos y el sistema pronosticó efecto positivo en siete y negativo en cinco. (De la Cruz & Barceló, 2009).

1.3 PLANTEAMIENTO DEL PROBLEMA

El Campo GGV se considera como un campo maduro, es decir, que después de un largo período de producción la energía natural del yacimiento ha declinado lo que deriva en una pérdida de producción, por lo que se aplica un SLA, los cuales permiten levantar la columna de fluido a superficie, cuyo propósito es aumentar los caudales de producción al evaluar las condiciones actuales de los pozos y por ende mejorar la productividad del campo.

Actualmente, la empresa Pacifpetrol S.A es la que opera en el campo, el cual cuenta aproximadamente con 2880 pozos, con una trayectoria de más de 100 años de vida productiva del yacimiento, produciendo con tres SLA; SW, HL y BM de los cuales el campo se separa por secciones que se encuentran en producción: 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, Certeza, Santa Paula, Valparaíso, Petrópolis, Matilde, Carmela y Tigre. El principal problema del Campo es la baja producción, debido a la depletación del yacimiento, generando pérdida de presión de flujo, altos costos de operación y mantenimiento, el estudio se enfoca en dar solución a ese problema; aplicando la tecnología de IA por medio de machine learning será más fácil la determinación de la

selección del SLA en la sección 66 capaz de aumentar la productividad y que compense la inversión requerida en el menor tiempo posible para prolongar la vida de este campo.

En la sección 66, los problemas de los pozos son causa de elevados cortes de agua, baja producción, desprendimiento de tubería, rotura de tubería, recuperación de copas, bolas, botellas y la válvula de retención, demora en pistonear, pesca de varillas, bomba embastonada.

1.4 JUSTIFICACIÓN

La IA se ha usado en pronósticos para el área de negocios, logística, economía y otros ámbitos de conocimiento a partir de la década de los 90. Sin embargo, en la industria del petróleo ha estado presente en los últimos años, específicamente desde el 2009 con investigaciones teóricas empleadas para obtener información de ambientes complejos cuyo modelamiento analítico era desconocido, y desde el 2017 con la ejecución de proyectos en operaciones *upstream*, *mainstream*, y *downstream*.

Por tanto, en base a la reciente aplicación de la técnica machine learning en procesos de la industria petrolera alrededor del mundo relacionados con perforación, almacenamiento, transporte, procesamiento de crudos, optimización de operaciones en producción y dado que en Ecuador esta tecnología no se ha implementado en proyectos, apenas existen algunos estudios preliminares y no hay proyecto similar respecto a la selección del SLA en la sección 66 del campo GGV mediante IA, proponer el presente trabajo ofrece una aplicación de esta tecnología en el área de estudio.

En la sección 66 del Campo GGV, muchos de los pozos tienen una producción muy baja, esto debido a diferentes factores, entre ellos está el método por el cual están produciendo, en dicha sección se opera con SLA por BM, HL y SW, esto amerita un estudio de factibilidad para determinar un único sistema mediante la técnica machine learning, empleando un algoritmo capaz de evaluar con precisión los datos y predecir resultados en función de una variable determinada, para ello, se realiza un análisis concerniente de las condiciones operativas, historial de producción, costos de operaciones y mantenimientos, lo que ayudará en la toma de decisión para la selección del único y óptimo SLA para operar en la sección 66 con el fin de incrementar la producción, a su vez que sea rentable para la compañía Operadora Pacifpetrol.

1.5 OBJETIVOS

1.5.1 Objetivo general.

- Realizar un estudio de factibilidad que permita evaluar los sistemas de levantamiento artificial mediante la aplicación de inteligencia artificial, para conocer cuál de los métodos es el óptimo a implementar en un futuro, en la sección 66 del campo GGV.

1.5.2 Objetivos específicos.

- Identificar cada uno de los SLA con los que se está produciendo actualmente en la sección 66 del campo GGV.
- Describir las ventajas y desventajas que pueden ofrecer los SLA con los que están produciendo los pozos.
- Aplicar un algoritmo de machine learning a los diferentes SLA presentes en la sección 66.
- Analizar y comparar los diferentes resultados obtenidos del algoritmo.
- Realizar un análisis de costo-beneficio para determinar la viabilidad del proyecto.

1.6 ALCANCE DE LA PROPUESTA

El alcance del proyecto se enfoca en identificar los pozos junto con sus respectivos métodos de SLA que están produciendo en la sección 66 del campo GGV, en los cuales se realiza un estudio para obtener dataset. A partir de un algoritmo de IA dicho dataset es analizado a fin de conocer cuál de los métodos de SLA que actualmente están produciendo es el más factible a implementar en toda la sección y así aumentar la producción.

1.7 HIPÓTESIS DE TRABAJO

La aplicación de machine learning hace posible determinar que el método de levantamiento artificial por bombeo mecánico es el más factible a implementar en toda la sección 66 del Campo GGV.

1.8 VARIABLES

1.8.1 Variable independiente.

- Algoritmo machine learning.

1.8.2 Variables dependientes.

- Tasa de producción de los pozos.
- Costos operativos.
- Método de levantamiento artificial seleccionado.
- Precisión.
- Tasa de error.

CAPÍTULO II: MARCO TEÓRICO

2.1 DESCRIPCIÓN DEL CAMPO GGV

2.1.1 Ubicación del campo.

El GGV se encuentra ubicado en la península de Santa Elena al sureste de la provincia del Guayas, tiene una extensión total de 1200 km², de las cuales 480 km² (40%) se encuentran fuera de la costa y 720 km² (60%) en superficie terrestre como se muestra en la Figura 1. En el campo se han perforado aproximadamente 2882 pozos. El área de estudio se encuentra localizada dentro del Campo “GGV” en el área centro sección 66, las coordenadas se muestran en la Tabla 1 y Tabla 2. (García & Martínez , 2006)

Tabla 1. Coordenadas graficas campo GGV (Pacifpetrol, 2021)

Latitud Sur	Longitud Oeste
2°15'8.11''	80°51'53.51''
2°17'17.8''	80°51'53.51''
2°17'17.8''	80°50'48.65''
2°15'8.11''	80°50'48.65''

Tabla 2. Coordenadas UTM campo GGV (Pacifpetrol, 2021)

Latitud Norte	Longitud Este
N9'751.000	E515.000
N9'747.000	E515.000
N9'747.000	E517.000
N9'751.000	E517.000




Figura 1. Ubicación del campo GGV (García & Villón, 2014)

2.1.2 Historia de explotación.

El primer pozo petrolero del país fue perforado en el campo Ancón en el año 1911, de nombre Anc-0001 (ver Figura 2), la compañía petrolera encargada de la exploración, en ese año, fue Anglo Ecuadorian Fields. Ltd., En el año 1921, el segundo pozo fue el verdadero inicio de un programa intensivo de exploración, desarrollo y producción que culminó con una producción de 10 000 barriles en el año 1956. (Veloz & Velastegui , 2007)

En el año 1917, dos empresas controlaban el campo Ancón; la operadora más importante fue Anglo-Ecuadorian Oilfields Ltd. (AEO) en la zona sur de la península, la cual explotó los campos de Ancón hasta 1964 y controló el 75% de la producción en la región y en la zona norte Ecuador Oilfields Ltd. otra compañía de origen británico, que descubrió en 1934 el campo Tigre en cercanías de Ancón. En 1961, los operadores suspendieron las actividades de perforación para sólo concentrarse en la producción de las zonas desarrolladas del campo. (Veloz & Velastegui , 2007)

En abril de 1996 la Escuela Superior Politécnica del Litoral (ESPOL), administradora de los campos, para entonces por decreto gubernamental, suscribió con la compañía CGC un contrato de operación y desde el año 2002 la compañía Pacifpetrol pasó a operar el campo hasta la actualidad. (García & Martínez , 2006)



Figura 2. Pozo Anc-0001: (García & Villón, 2014)

2.1.3 Historial de producción

La producción del campo Ancón es obtenida del reservorio de edad Terciaria; desde ese entonces concentró 110 MMbbls que, porcentualmente, corresponden al 95% de la producción acumulada, y el 5% restante (6 MM bbls) proviene de pequeños yacimientos, cuya producción es de reservorios de edad Cretácica (Petrópolis, Achallan, Carolina, San Raymundo, Cautivo, Santa Paula. (García & Martínez , 2006)

2.1.4 Producción acumulada de petróleo (N_p) en cada sección

Es la sumatoria de los volúmenes de petróleo que se han producido en una fecha dada. La producción se mide en condiciones definidas para permitir el cálculo tanto del volumen de vaciamiento del yacimiento como el volumen de ventas, para el propósito del vaciamiento del yacimiento también se incluyen las cantidades no petrolíferas. Este parámetro es muy importante porque nos permite evaluar la formación petrolífera; ya que esta información proporciona varios propósitos, en este caso la evaluación de cambio de SLA para una mejor alternativa del campo. La producción acumulada en la sección 66 es de 4'343,889 Barriles como se muestra en la Figura 3 y Tabla 3. (García & Villón, 2014)

Tabla 3. Producción acumulada de petróleo del campo GGV (Pacifpetrol, 2021)

Sección	Np
066	4'343,889
067	2'114,619
068	7'135,010
069	6'362,476
070	6'097,004
071	5'257,992
072	10'629,062
073	13'459,548
074	9'438,257
Carmela	1'362,353
Certeza	3'680,824
Morrillo	1,605
Petrópolis	2'078,050
Santa paula	5'392,351
Tigre	11'251,228
Np total	107'637,271




Figura 3. Producción acumulada de petróleo (Np) del campo GGV (Pacifpetrol, 2021)

2.1.5 Reservas del campo

Según el grado de confianza en recuperar los volúmenes declarados, las reservas se clasifican en probadas, probables y posibles, las reservas del campo se muestran en la Tabla 4

Las reservas probadas son todos los volúmenes de hidrocarburos en el yacimiento estimado con razonable certeza y recuperables de yacimientos conocidos, de acuerdo con la información geológica y de ingeniería disponible, bajo las distintas condiciones operacionales. El término "razonable certeza" indica un alto grado de confianza en las cantidades estimadas que serán recuperadas para poder iniciar las operaciones. (Pillasagua & Rodríguez , 2014)

En términos probabilísticos, debe existir al menos un 90% de probabilidad de recuperar el volumen declarado o un volumen superior. (Tituaña, 2018)

Las Reservas Probables son todas aquellas reservas que se encuentran en el límite del yacimiento, los volúmenes estimados del yacimiento de hidrocarburos asociados a las acumulaciones conocidas, en los cuales la información geológica, de ingeniería, contractual y económica, bajo las condiciones operacionales prevalecientes, indican (con un grado menor de certeza al de las reservas probadas) que se podrán recuperar (Pillasagua & Rodríguez , 2014)

En términos probabilísticos debe existir al menos un 50% de probabilidades de recuperar la suma de Reservas Probadas más Probables. (Tituaña, 2018)

Las Reservas Posibles es el volumen de hidrocarburos medido en condiciones atmosféricas de un yacimiento que será recuperado lo que queda del mismo, si es económicamente rentable, con las técnicas de explotación aplicables. En otra forma, es la diferencia entre la reserva original y la producción acumulada de hidrocarburos en una fecha específica. (Pillasagua & Rodríguez , 2014)

En términos probabilísticos, debe existir al menos un 10% de recuperar la suma de Reservas Probadas más Probables más Posibles. (Tituaña, 2018)

Tabla 4. Reservas del campo GGV (Pacifpetrol, 2021)

Formación	Reserva total (MMbbls)	Reserva probada (MMbbls)	Reserva probable (MMbbls)	Reserva posible (MMbbls)
Socorro	31,47	0,21	0,01	0,01
Clay Pebble Beds	2,33	0,50	0,02	0,01
Santo Tomas	12,17	0,47	0,01	0,01
Passage Beds	2.42	1,01	0.03	0,01
Atlanta	73,53	0.10	0.67	
Santa Elena	6,43	0,32		

2.1.6 Propiedades de los fluidos

El petróleo es una sustancia aceitosa de color oscuro a la que, por sus compuestos de hidrógeno y carbono, se lo denomina hidrocarburo. El crudo del campo GGV se caracteriza por ser liviano, tiene 37.8 ° API como se muestra en la Tabla 5 promedio, con las siguientes características de la roca madre que acoge a este hidrocarburo: Temperatura al momento de la expulsión (121-122) °C, Gradiente geotérmico al momento de la expulsión de 2,4 °C/100m, Profundidad mínima del tope de generación de (4100 m; 13452,1 ft), Gravedad específica 0.8457. (Pacifpetrol, 2021)

Para determinar las propiedades de los fluidos de los yacimientos es necesario realizar una toma de muestras de fluidos en condiciones de confinamiento, tal que los resultados sean valores confiables para posteriores estudios de los reservorios (Ricardo, 2013)

El factor volumétrico del petróleo se define como la razón entre el volumen de petróleo más su gas en solución, a condiciones de yacimiento, respecto al volumen de un barril de petróleo producido medido a condiciones de superficie. (Ricardo, 2013)

La gravedad API, de sus siglas en inglés American Petroleum Institute, es una medida de densidad que describe qué tan pesado o liviano es el petróleo comparándolo con el agua. Si los grados API son mayores a 10, es más liviano que el agua, y por lo tanto flotaría en esta (Ricardo, 2013)

La fórmula usada para obtener la gravedad API (1) es la siguiente:

$$^{\circ}API = \frac{141.5}{SG} - 131.5 \quad (1)$$

Tabla 5. Gravedad API promedio de las formaciones productoras (Pacifpetrol, 2021)

Formación	Gravedad API	Bo (By/Bn)
Socorro	36.8	1200
Clay Pebble Beds	39	1200
Santo Tomas	38.8	1200
Passage Beds	39	1200
Atlanta	40	1200
Santa Elena	33.6	1200

2.1.7 Producción diaria

Actualmente, en el campo existen 2882 pozos, sin embargo, no todos están produciendo, solo el 49,20 % es decir 1418 pozos son productores, 1459 pozos que representan el 50,62% se encuentran parados, y 5 (0,18%) son pozos abandonados debido a que su producción era muy baja y presentaban problemas. Ver Tabla 6

Tabla 6. Producción y estado de los pozos del campo GGV (Pacifpetrol, 2021)

SLA	Número de pozos	Producción	Porcentaje de producción
BM	318	585,39	53,77
HL	798	285,78	26,25
SW	289	202,44	18,59
PT	3	9,13	0,84
FY	10	5,94	0,55
Subtotal	1418	1088,68	100%
Parados transitorios	1459	0	0
Abandonados	5	0	0
Total	2882	1088,68	100%

2.1.8 Estructura geológica

El cantón Santa Elena está situado en la cuenca homónima, llamada “Levantamiento de Santa Elena” y constituye el conjunto de zonas sedimentarias del Cretácico al Terciario Inferior (Paleoceno-Eoceno), formada sobre la corteza oceánica. (García & Villón, 2014)

La definición del modelo geológico del campo Ancón y el área circundante, complejidad estructural y sedimentaria, correlación de perfiles eléctricos e información sísmica, definieron el modelo estructural de la Península y los principales rasgos estructurales vinculados a los campos. Los primeros modelos conceptualmente oscilaban entre una Tectónica Distensiva, acompañada por pliegues a una tectónica de gravedad con la participación de estructuras Caóticas.. (García & Villón, 2014)

2.1.9 Litología del campo

Formación Piñón (Jurásico-Cretácico Medio). - La formación Piñón de la edad Aptiano Superior-Albiano, de aproximadamente 180 Ma (Jurásico medio), se caracteriza principalmente por ser de origen oceánico y naturaleza basáltica. La componen basaltos afaníticos almohadillados, doleritas intrusivas y algunas intrusiones gabroides y ultramáficas. (Oña & Armijos, 2018)

Formación Cayo (Cretácico). - La formación Cayo está formada de una espesa secuencia volcánica y volcanosedimentario, la cual se caracteriza principalmente por no aflorar en la Península, con un espesor de 3 Km aproximadamente. Esta formación está compuesta por sedimentos 34 marinos (Lutitas bituminosas y turbiditas finas), volcánicos (lavas almohadilladas) y volcanoclásticos (tobas). (Oña & Armijos, 2018)

Formación Santa Elena (Cretácico). - La Formación Santa Elena muestra depósitos finos turbidíticos de aguas profundas, flujos de detritos y deslizamientos. Se formó en la edad del Cretácico y viene representada por finas elevaciones de radiolaritas y pelitas silíceas estratificadas con colaboración de tobáceas que muestran colores blanquecinos. Son caracterizados en su conjunto por una deformación dúctil con incremento de clivaje penetrativo que ayuda a determinar fallamientos y pliegues. (Calderón Enríquez, 2013)

Formación Azúcar Atlanta (Paleoceno). - La formación Azúcar o también conocida como formación Atlanta de edad Paleoceno Eoceno inferior, se encuentra ubicada entre la formación Santa Elena y el Grupo Ancón, se la considera como la principal formación de interés del campo petrolero Ing. Gustavo Galindo Velasco. Compuesta principalmente por una arenisca gris dura con textura media gruesa. Tradicionalmente esta estructura geológica estaba constituida por tres formaciones o facies que son: a) Facies La Estancia. b) Facies Chanduy. c) Facies Engabao (Oña & Armijos, 2018)

Grupo Ancón (Eoceno). - Formada en la edad del Eoceno, consta de un grupo de formaciones que lleva el mismo nombre del campo petrolero Ancón, su composición se basa en rocas silicoclásticas. Está conformada por las siguientes formaciones: Fm. Punta Ancón, Fm. Seca, Fm. Socorro, Passage Beds (PB), Clay PeBble Beds (CPB), Arenisca Santo Tomas. (Calderón Enríquez, 2013)

- **Passage Bed** (Capas de transición). - Se forma mediante capas de transición constituidas por rígidos estratos de areniscas delgados, además se intercalan con areniscas calcáreas. (García & Villón, 2014)
- **Clay PeBble Beds** (Eoceno inferior). - Esta formación pertenece a la edad Eoceno Medio, la cual posee un espesor de 180 m. Comprende una serie diamictítica maciza de matriz arcillosa con un tope que aflora en los acantilados de Ancón. (Oña & Armijos, 2018)
- **Arenisca Santo Tomas**. - Compuesta por un conjunto de areniscas de potencias poco relevantes conocida únicamente en el subsuelo de Ancón, específicamente en la parte NE de este campo. Se encuentra en la culminación del ciclo turbidítico de la Fm Passage Beds. (García & Villón, 2014)
- **Formación Socorro** (Eoceno Medio temprano). - Es el segundo yacimiento más importante del campo Ancón, pertenece a edades Eoceno Medio-Superior a Eoceno Superior. Según Marchant (1956) esta formación geológica posee un espesor medido de 390 m y un espesor máximo perforado en el subsuelo de 457 m. Configuran una variación de lutitas deleznales grises hasta negro y areniscas turbidíticas delgadas con tonalidad verdosa. (Oña & Armijos, 2018)

- **Formación Seca (Eoceno medio).** - La formación Seca de edad Eoceno Medio a Superior, es una estructura geológica de 300 m de espesor promedio, compuesta de arcillitas grises de tonalidad verdosa con anómalas intercalaciones de areniscas finas que en su tope alcanza una coloración amarillenta rojiza y se caracteriza principalmente por formar el sello de los yacimientos de la Fm. Socorro. (Oña & Armijos, 2018)
- **Formación Punta Ancón.** - (Eoceno Medio a Superior). La formación Punta Ancón de edad Eoceno Medio a Superior, es una estructura geológica de 160 m de espesor, compuesta de areniscas grises con base erosiva con variaciones de pelitas grises (Calderón Enríquez, 2013)

Formación Tablazo (Pleistoceno). - La Formación Tablazo fue formada en la edad del Pleistoceno, consta de calizas arenosas con bancos de conchillas y areniscas gruesas. Se sitúa sobre las rocas cretácicas y paleógenas de la Península de Santa Elena. Son escasamente potentes (hasta algunas decenas de metros: promedio 30 m) y se disponen sub horizontalmente. (Oña & Armijos, 2018)

A continuación, se muestra en la Figura 4 un corte geológico y en la Figura 5 las características de la litología del campo GGV:




Figura 4. Corte geológico del campo GGV: (Oña & Armijos, 2018)

BLOQUE SANTA ELENA - MARCO ESTRATIGRAFICO

Periodo	Epoca	Edad	Unidades	Esp. (m)	Lithología	Ambiente Depositional		
Cuaternario	Pleistoceno		TABLAZO Fm.	30	Areniscas Calcareas	Marino Somero		
TERCIARIO	Eoceno	Bartoniano	PUNTA ANCON / ZAPOTAL Fm	150	Areniscas Gruesas	Marino Somero		
		Medio	SECA Fm	500	Lutitas, limolitas y margas	Plataforma intermedia a marino somero		
			SOCORRO Fm	460	Turbiditas finas y arcillas	Facies de talud a plataforma externa		
			CPB Fm	0-650	Santo Tomas Sst	Arcillas conglomeraticas Diamictitas	Depósitos de remoción en masa en ambiente de talud ("Slumps")	
		PASSAGE BEDS Fm	Turbiditas Finas		Abanicos turbidíticos -relleno de cuencas de talud			
	Ypresiano	Paleoceno	Thanetiano	AZUCAR Fm. / ATLANTA Fm.	Engabao Fs	1500 2000	Areniscas turbidíticas gruesas Conglomerados y lutitas oscuras	Complejo de abanicos turbidíticos depositados en ambiente marino profundo (Basin Floor Fans) Turbiditas de alta densidad con participación minoritaria de flujos de baja densidad
			Chanduy Fs					
			Estancia Fs					
	Daniano	SANTA ELENA Fm	500	Arcillas pelágicas silisificadas, turbiditas cherts intrusivos doleríticos	Sedimentación pelágica coetanea con vulcanismo activo Turbiditas de baja densidad			
	CRETACICO	SENONIANO	Maestriciano	CAYO Fm	2000	Tobas, lutitas oscuras turbiditas con aporte piroclásticos	Secuencia grano creciente de turbiditas de alta a baja densidad con intercalaciones de lutitas pelágicas	
Campaniano								
Santoniano								
Coniaciano								
Tardío		Turoniano	PIÑON Fm	?	Basaltos, doleritas intrusivos ultramáficos	Fondo Oceánico		
		Cenomaniano						
		Albiano						
		Aptiano						

Figura 5. Columna estratigráfica del campo GGV: (Oña & Armijos, 2018)

2.2 ESTADO ACTUAL DE LOS POZOS EN LA SECCIÓN 66

En la sección 66 del campo GGV hay un total de 60 pozos, de los cuales 27 están cerrados (45%), 1 es usado como pozo inyector (2%) y 32 son productores (53%), para caso de estudio se tomarán en cuenta solo los pozos productores. Ver Figura 6 y Tabla 7




Figura 6. Porcentual de pozos según su estado (Pacifpetrol, 2021)

Tabla 7. Estado de pozos Campo GGV "sección 66" (Pacifpetrol, 2021)

Estado	Nº de pozos
Productores	32
Inyectores	1
Cerrados	27

Para la extracción del petróleo en la sección 66 se utilizan los siguientes SLA; BM, HL y SW. De los 32 pozos productores que hay en la sección; 10 operan con SLA por BM es decir el (31%), 14 con HL (44%) y 8 con SW o Pistoneo (25%).

A continuación, en la Figura 7 se detalla la producción diaria en barriles de cada SLA que opera en dicha sección, la formación de la cual se está produciendo y la profundidad del pozo




Figura 7. Porcentual de SLA usados en la sección 66 (Pacifpetrol, 2021)

En la Tabla 8. Se presentan los pozos productores de la sección 66, cada con su respectivo nombre, la formación de la que están obteniendo su producción; Atlanta (AT), Clay Pebble Bed (CPB), Passage Beg (PB), Santo Tomas (ST), además del SLA con el cual están produciendo; BM, HL, SW, los ciclos y el basic sediment and water (BSW) corresponde al contenido de agua libre (no disuelta) y sedimentos (limo, arena) que trae el crudo. Es importante que su valor sea bajo, para evitar suciedades y dificultades durante el procesamiento del crudo.

Tabla 8. Pozos productores del campo GGV "sección 66" (Pacifpetrol, 2021)

Nombre	Fm. productora	Sistema de levantamiento	Ciclos	Bsw	Coordenadas x	Coordenadas y
ANC0437	AT	BM	1	0,08%	519517	9744015
ANC0446	AT	BM	1	0,05%	519555	9743553
ANC0458	AT	BM	4	0,05%	519094	9744194
ANC0461	AT	BM	1	0,10%	519181	9743299
ANC0465	AT	BM	1	0,05%	520406	9743157

Tabla 9. (Continuación)

ANC0504	AT	BM	1	0,05%	519737	9743002
ANC0508	AT	BM	4	0,05%	519458	9744464
ANC0585	AT	BM	1	0,05%	520314	9743826
ANC0656	AT	BM	8	0,05%	519539	9743783
ANC0778	AT	BM	1	0,05%	519578	9743328
ANC0420	AT	HL	12	0,05%	519957	9743336
ANC0424	AT	HL	8	0,05%	520284	9743556
ANC0434	AT	HL	6	0,10%	519887	9744278
ANC0582	AT	HL	12	0,10%	520101	9743883
ANC0667	AT	HL	25	0,05%	519046	9744671
ANC1073	CPB	HL	2	0,05%	519112	9743143
ANC1393	CPB	HL	12	0,05%	519630	9744313
ANC1395	CPB	HL	30	0,05%	519870	9744058
ANC1396	CPB	HL	15	0,05%	520195	9744128
ANC1703	CPB	HL	6	0,05%	520481	9743678
ANC1713	ST	HL	25	0,05%	520522	9743482
ANCFA02	CPB	HL	3	0,05%	519010	9743922
ANCFA13	PB	HL	30	0,05%	520210	9744270
ANCFA22	PB	HL	4	0,05%	519148	9743548
ANC0162	CPB	SW	3	0,05%	518933	9743117
ANC0163	AT	SW	2	0,05%	519520	9743111
ANC0589	AT	SW	8	0,05%	518993	9745103
ANC0655	AT	SW	7	0,05%	519757	9743643
ANC1493	CPB	SW	4	0,05%	518806	9743580
ANC1648	AT	SW	6	0,05%	518937,1	9745861,4
ANC1678	CPB	SW	4	0,05%	519917	9743849
ANC3007	AT	SW	3	0,05%	519240	9744050

De acuerdo con los datos obtenidos, 20 pozos productores de la sección 66 obtienen su producción de la fm AT de los cuales; 10 producen con SLA por BM, 5 con HL y 5 con SW. 9 pozos producen de la fm CPB; 6 con HL y 3 con SW, 2 pozos operados con HL producen de la formación PB y 1 pozo operado con HL obtiene su producción de la

formación ST, con estos datos se considera a la fm AT como la más importante en la sección 66. Ver Figura 8

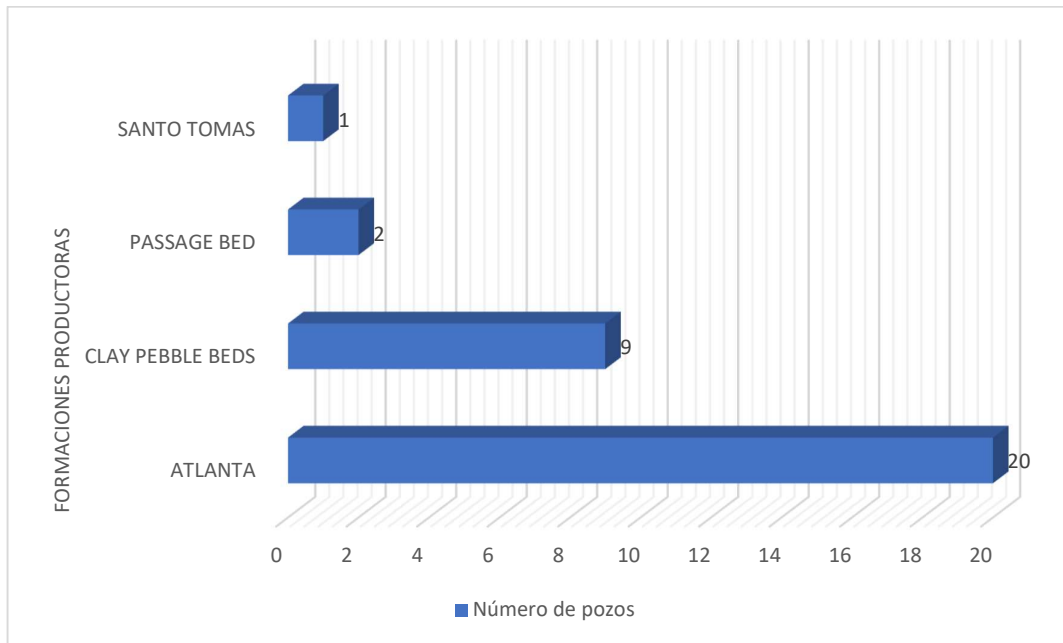


Figura 8. Numero de pozos que producen de cada formación productora (Pacifpetrol, 2021)

En comparación a las otras formaciones, AT es la que tiene mayor reserva totales siendo de 73.53 MMbbls, le sigue la formación Santo Tomás con 13.17 MMbbls, las que menos reserva presentan son CPB Y PB con 2.53 y 2.42 MMbbls, respectivamente. Ver Figura 9

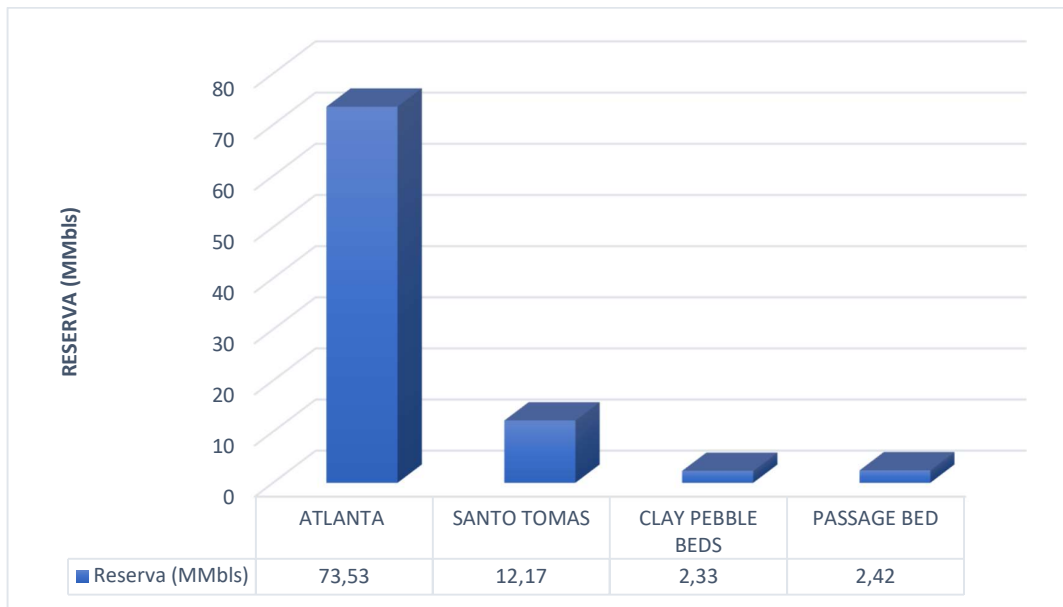


Figura 9. Reserva de las formaciones productoras (Pacifpetrol, 2021)

En el campo GGV la declinación promedio de la producción es de 0.25% mensual, para caso de estudio se tomaron los datos de producción desde enero de 2016 a diciembre del 2020. La producción diaria promedio de los pozos que operan con SLA por BM en la sección 66 está entre “0.46-4.66” barriles por día. Ver Figura 10

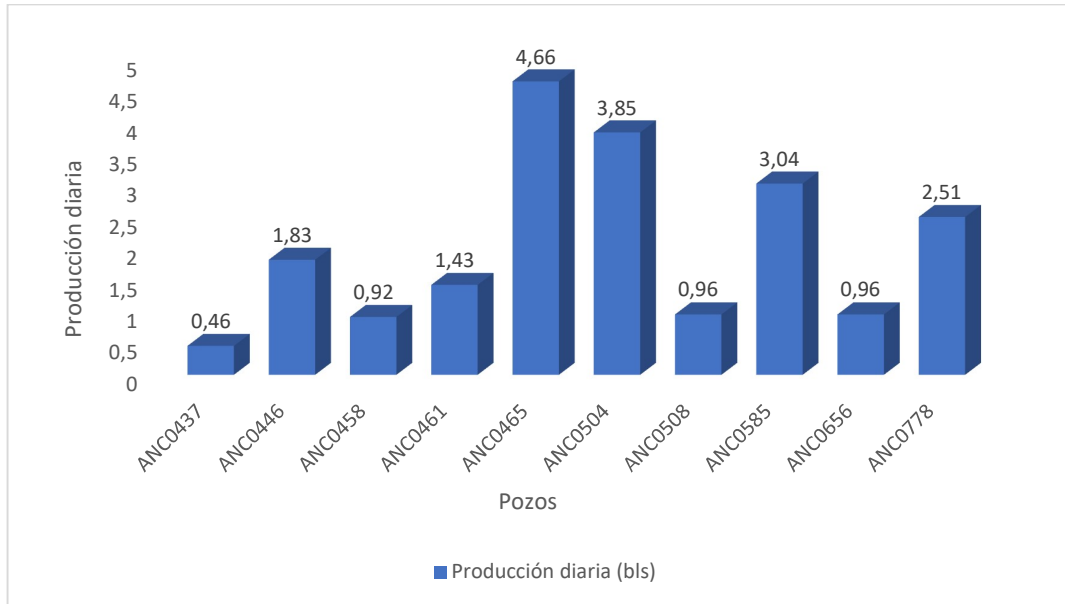


Figura 10. Producción diaria de pozos que operan con BM (Pacifpetrol, 2021)

La producción promedio diaria de los pozos que operan con SLA por HL en la sección 66 está entre “0.03-0.69” barriles por día, con este sistema se obtiene una producción muy baja en comparación a pozos que producen con otro SLA. Ver Figura 11

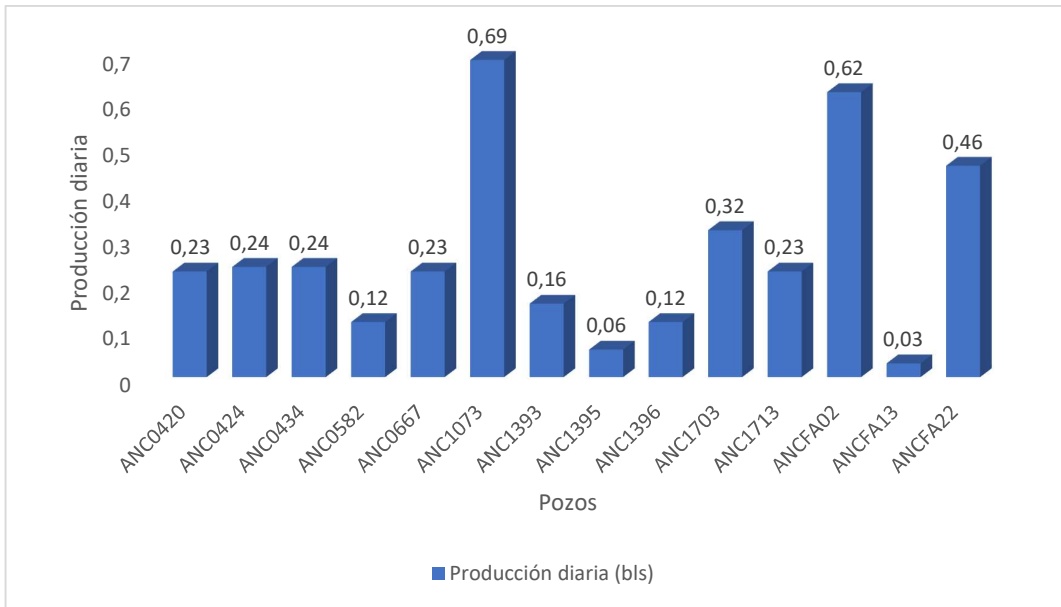


Figura 11. Producción diaria de pozos que operan con HL (Pacifpetrol, 2021)

La producción diaria de los pozos que operan con SLA por SW o Pistoneo en la sección 66 está entre “0.47-1.87” barriles por día. Ver Figura 12

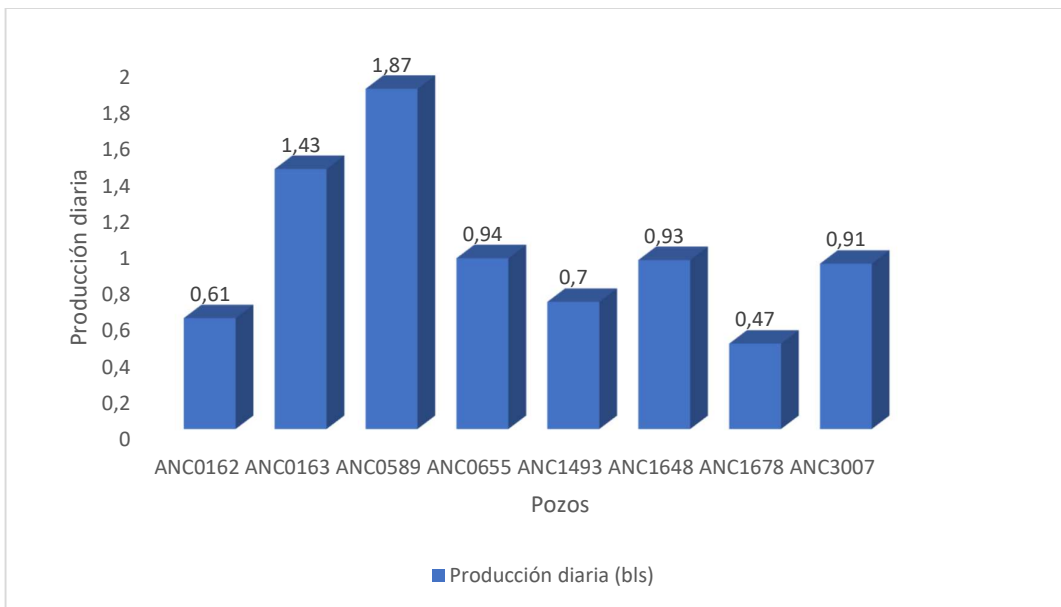


Figura 12. Producción diaria de pozos que operan con SW (Pacifpetrol, 2021)

2.3 DESCRIPCIÓN DE LOS SISTEMAS DE LEVANTAMIENTO ARTIFICIAL

Los SLA son el primer elemento al cual se recurre cuando se desea incrementar la producción en un campo, ya sea para reactivar pozos que no fluyen o para aumentar la tasa de flujo en pozos activos. Estos operan de diferentes formas sobre los fluidos del pozo, ya sea modificando alguna de sus propiedades o aportando un empuje adicional a los mismos, generalmente son utilizados cuando el pozo deja de producir por flujo natural, se requiere el uso de una fuente externa de energía la cual concilia la oferta con la demanda de energía. El propósito de este método es minimizar los requerimientos de energía en la cara de la formación productora, con el objeto de maximizar el diferencial de presión a través del yacimiento y provocar, de esta manera, la mayor afluencia de fluidos. (Pillasagua & Rodríguez , 2014)

Los sistemas de extracción empleados en la sección 66 del Campo Ancón por PACIFPETROL para la producción de petróleo son: BM, HL, SW ver Figura 13, Figura 14 y Figura 15

2.3.1 Bombeo mecánico



Figura 13. Unidad de BM utilizada en el campo GGV. (García & Villón, 2014)

- a) **Generalidades del sistema.** El BM es uno de los SLA más utilizado más antiguos y utilizado en la industria del petróleo. Utiliza una unidad de bombeo con la cual transmite movimiento a la bomba subsuperficial a través de un conjunto de varillas, y la energía es suministrada por un motor. *(García & Villón, 2014)*

Consiste en una bomba de subsuelo de acción recíprocante, abastecida con energía que se trasmite a través de una denominada sarta de varillas (o cabillas).

La bomba se ubica en el hoyo, frente a la cara de la formación, es ahí donde se genera un diferencial entre la presión de fondo y la presión del yacimiento, de tal manera que favorezca la succión de la bomba. De esta manera se convierte el movimiento rotacional del motor en un movimiento ascendente y descendente, con el fin de llevar los fluidos del yacimiento a superficie. *(García & Villón, 2014)*

- b) **Principio operativo.** Este método de extracción levanta el fluido desde el fondo del pozo hasta superficie y luego lo impulsa hacia el tanque de recolección. La bomba de 25 subsuelos es accionada por el movimiento recíprocante de la Unidad de Bombeo transmitido por una sarta de varillas. *(Ricardo, 2013)*

La Unidad de Bombeo en su movimiento tiene dos puntos muy bien definidos, muerto superior y muerto inferior. Cuando el balancín está en el punto muerto inferior, las válvulas fijas y viajeras están cerradas. Al comenzar la carrera ascendente, la presión de fondo y el efecto de succión del pistón permiten la apertura de la válvula fija; por tal motivo, el fluido pasa del pozo hacia el interior de la bomba. Al mismo tiempo, la columna de fluido ejerce una presión sobre la válvula viajera y permanecerá cerrada durante la carrera ascendente. El fluido continúa llenando la bomba hasta llegar a punto muerto superior; la válvula fija se cierra y comienza la carrera descendente; el pistón se mueve hacia abajo y produce el efecto de compresión, al chocar con el fluido, la presión interna abre la válvula viajera; el pistón continúa su carrera descendente, mientras el fluido es transferido a la tubería de producción hasta llegar al punto muerto inferior; y, se repite el ciclo. *(Ricardo, 2013)*

- c) **Equipos en superficie y subsuelo.** Es la parte en el cual se desarrolla como soporte en el sistema de bombeo espontáneo, generando también la energía necesaria para el buen funcionamiento del sistema.

El equipo de superficie incluye:

- **Motor de la unidad:** El motor es considerado como una máquina motriz que suministra la fuerza requerida para la operación de la unidad. Los motores se los utiliza para abastecer de energía mecánica a las unidades de bombeo para que logren llegar a la superficie los fluidos del pozo. En este campo petrolero se maneja únicamente 41 motores de combustión interna a gas, este gas es el mismo que emana del pozo, ya que el campo está muy alejado de las fuentes que suministran energía eléctrica; por lo tanto, no se instalan motores eléctricos porque la inversión sería muy alta. Dentro de los motores de combustión interna tenemos: motores de alta velocidad y baja velocidad, los mismos que se utilizan considerando los requerimientos para realizar el bombeo con la unidad. (Ricardo, 2013)
- **Unidad de bombeo:** Es el mecanismo mediante el cual se convierte el movimiento rotatorio del motor, en movimiento recíprocante vertical en las varillas de bombeo, reduciendo a su vez la velocidad del motor primario a una velocidad de bombeo deseada. (Ricardo, 2013)
- **Estructura:** es la parte principal estructural de la unidad de bombeo, es la base la cual se fabrica con perfiles de acero. Sirve como miembro rígido que une el soporte maestro, reductor y motor con una alineación apropiada para el mecanismo de trabajo. (Ricardo, 2013)
- **Soporte maestro:** constituido de tres soportes de perfiles de acero. Debe tener suficiente rigidez y resistencia para soportar el doble de la carga máxima del varillón pulido. (Ricardo, 2013)
- **Bloque viajero:** este elemento está constituido de un perfil de acero, el mismo que se coloca sobre un cojinete central que se encuentra en el centro del soporte maestro. (Ricardo, 2013)

- Biela: es un elemento fabricado de acero, el mismo que sirve para transmitir el movimiento al bloque viajero (Ricardo, 2013)
- Barra lisa: Es una varilla de acero sólido, disponible en varios tamaños, longitudes y equipadas con conexiones de varillas en ambas puntas. (Ricardo, 2013)
- Reductor de velocidades: es un conjunto de engranajes helicoidales cuyo objetivo es reducir la velocidad y cambiar el movimiento de rotación entre el motor y el sistema biela - manivela que este accionado por medio de correas o bandas. (Ricardo, 2013)
- Elevador: es un elemento que sirve como unión entre los cables y el varillón pulido, permitiendo de esta manera transmitir el movimiento rectilíneo vertical del varillón pulido sin dificultad. (Ricardo, 2013)
- Caja prensa estopas – Stuffing-Box: Es un dispositivo unido a la T de bombeo que sella los fluidos en la tubería, formando un sello hermético con la varilla lisa y desviando los fluidos producidos fuera de la T de bombeo hacia la línea de flujo (Ricardo, 2013)
- Cabezal de pozo: es el regulador (por medio de válvulas) del manejo de fluido y presión comúnmente utilizado en cuestiones hidráulicas, los pozos utilizan este sistema para regular la salida del líquido. Provee la base para el asentamiento mecánico del ensamblaje en superficie (Ricardo, 2013)
- Líneas de flujo: conectan el cabezal del pozo con el separador. Las altas presiones en la línea de flujo pueden provocar altas cargas en la barra pulida y una disminución en la eficiencia, mientras más grande sea el tamaño del pistón, más grande será el efecto de la presión de la línea de flujo en el sistema (Ricardo, 2013)
- Manivela: transmite el movimiento de la caja de engranaje o transmisión a las bielas del balancín, que están unidas a ellas por intermedio de pines (Ricardo, 2013)
- Pesas o contrapesos: se utilizan para balancear las fuerzas desiguales que se

originan sobre el motor durante las carreras ascendente y descendente del balancín. Generalmente se encuentran ubicados en la manivela. (Ricardo, 2013)

- Caja de engranaje: su objetivo es reducir la velocidad de rotación entre el motor y el sistema biela-manivela. Pueden ser de un sistema de reducción simple, doble o triple. (Ricardo, 2013)

El equipo de subsuelo incluye:

- Revestimiento: son tuberías especiales que se introducen en el hoyo perforado y que luego son cementadas para lograr la protección del hoyo y permitir posteriormente el flujo de fluidos desde el yacimiento hasta superficie. (Ricardo, 2013)
- Tubería de producción: es una serie de tubos que se usa para transportar el fluido y, al mismo tiempo, sirve de guía a la sarta de varillas que acciona a la bomba (Ricardo, 2013)
- Sarta de varillas: son hechas de varias aleaciones de metales. Están sujetas a un funcionamiento mecánico que le impone esfuerzos de estiramientos, encogimiento y vibración, fatiga, corrosión y erosión (Ricardo, 2013)
- Válvula viajera: está ubicada en el pistón; permite la entrada de fluido del barril al pistón. (Ricardo, 2013)
- Válvula fija tipo bola y asiento: sirve para facilitar la entrada del fluido desde el pozo hasta el barril de la bomba. (Ricardo, 2013)

d) Ventajas

- Gracias al desarrollo de simuladores, hoy en día es muy fácil el análisis y diseño de las instalaciones.
- Puede ser usado prácticamente durante toda la vida productiva del pozo.

- La capacidad de bombeo puede ser cambiada fácilmente para adaptarse a las variaciones del índice de productividad, IPR.
- Puede producir intermitentemente mediante el uso de temporizadores o variadores de frecuencia conectados a una red automatizada.
- Puede manejar la producción de pozos con inyección de vapor.
- Alto porcentaje de eficiencia.
- Es operativo a bajas presiones de bombeo.
- Costos de reacondicionamiento bajo.
- El equipo es capaz de ponerse en marcha a temperaturas elevadas sin complicaciones.
- Puede utilizar alternadamente combustible o electricidad como fuente de energía.

e) Desventajas

- Susceptible de presentar bloque por excesivo gas libre en la bomba.
- En pozos desviados la fricción entre las cabillas y la tubería puede inducir a fallas de material.
- La unidad de superficie es pesada, necesita mucho espacio, en sitios poblados puede ser peligrosa para las personas.
- Cuando no se usan cabillas de fibra de vidrio, la profundidad puede ser una limitación
- Tiene dificultad de operación en pozos con alto grado de desviación.
- Su funcionamiento es ineficiente cuando existe alta producción de sólidos

2.3.2 Pistoneo o Swab



Figura 14. SLA Pistoneo o SW (García & Villón, 2014)

- a) **Generalidades del sistema.** Es una técnica de extracción de fluidos del interior de un pozo, desde una profundidad dada hacia la superficie. Esta operación se realiza debido a que la presión de la formación del pozo no es lo suficientemente mayor como para vencer la columna hidrostática que existe y poder expulsar el líquido drenado a la superficie. Para hacer producir estos pozos, se utiliza cable de acero que va enrollado en el winche o tambor de SW de la unidad de servicio de pozos (tubing o casing) y con ayuda de otros componentes y accesorios hacen posible la recuperación de fluidos. (García & Villón, 2014)
- b) **Procedimiento operativo.** La unidad de extracción por Pistoneo se ubica en la locación, es estabilizada por unos mandos hidráulicos, una vez cuadrada se levanta la pluma para iniciar la operación de extracción. Luego se coloca una reducción para que el fluido que se recuperará del pozo se dirija al tanque de almacenamiento de la unidad. El siguiente paso es soltar el standing valve por caída libre hasta la cruceta, si el pozo no tuviera standing fijo, esto ahorra significativamente tiempo en las labores de producción. Luego se baja el cable, que incluye el varillón copas y portacopas. (Ricardo, 2013)

Una vez alcanzado el nivel de fluido, se efectúan carreras ascendentes y descendentes que generan succión permitiendo al fluido que entre por la válvula

de retención (standing) y luego sobre las copas. El peso del fluido hace que las copas se hinchen y produzcan un sello para que el petróleo no retorne al fondo. Cuando el operador considere oportuno, levantará el conjunto de SW hasta la superficie y la producción se canaliza por la manguera de producción hasta el tanque de almacenamiento. (Ricardo, 2013)

c) **Problemas operacionales.** Cuando se interviene un pozo podemos encontrarnos con cualquier tipo de problema que dificulta la intervención. A continuación, se menciona algunos problemas operacionales: Tubos 2 3/8" colapsados (no se calibró o se colapsó por excesivo torque aplicado por la tenaza o llave hidráulica) que pueden aprisionar el conjunto de SW o no permitir que baje hasta el nivel de fluido, presencia de parafina suave o dura, rotura del tubo (por el rozamiento de la bajada del conjunto de SW, o deteriorado por la presencia de carbonato), atascamiento de herramientas, daños en el lubricador hidráulico (pérdida de tiempo), Desgaste y rotura de *cable*. (Ricardo, 2013)

Debido al exceso en el uso de repuestos, combustibles y servicios de pulling que se realizan en los pozos que utilizan este sistema, el costo es muy alto, esto lo convierte en el sistema más costoso del campo.

d) **Armada de equipo**

- Se procede a colocar el cácher (recolector de fluido) y reducciones de acuerdo con la tubería del pozo.
- Con el lubricador suspendido se coloca en la caja la porta copa con copa
- Si el pozo tiene herramienta (standing valve fijo), se procede a bajar; y en caso contrario, se envía la herramienta (standing valve viajero).
- Se baja el tubo lubricador con precaución y, con la comba de bronce, se ajusta la unión de golpe.
- El tanquero se cuadra en forma paralela a la Unidad de SW, a una distancia mínima de 02 metros de ésta, y a una distancia mínima de 5 metros del pozo.

- Una vez cuadrada la cisterna se activa el freno de estacionamiento (maxi brake).
- Se conecta manguera de la cisterna o carreta al tubo lubricador o a la línea de producción que se tiene en la Unidad.
- Una vez armado todo el Equipo de Pistoneo, se inicia el descenso del conjunto de SW (guardacabo, swivel, varillón, caja, porta copa con copa), por caída libre, la cual, es controlada con el freno manual del winche.
- El conjunto debe bajarse a velocidad moderada, hasta antes de llegar al nivel de fluido del pozo.
- Se continúa bajando con precaución el conjunto hasta el fondo (cruce o STVF).
- Una vez detectado el fondo se levanta el conjunto unos 10 pies y el operador coloca una señal al cable a la altura del mandril (marca).

e) Pistoneo del equipo

- Se inicia el enrollamiento de cable, controlando el alineamiento con la polea guiadora, (de ser necesario, retroceder tramos para corregir enrollamiento de cable).
- Durante el Pistoneo (ascenso y descenso del conjunto para cargar columna de fluido) se enrolla una determinada cantidad de cable que permita levantar el volumen encontrado, para dejar sin peso la válvula check, lo que va a permitir el ingreso de fluido proveniente del anular y de la formación, al interior de los tubos.
- Se repite el Pistoneo hasta cargar la columna de fluido por encima de la copa.
- Se realiza una primera corrida (el parámetro de eficiencia es 5,5 barriles de fluido por corrida).
- De ser necesario, se repite el ciclo hasta ir bajando el nivel y llegar hasta la trinca que es la señal que el pozo quedó seco.

- Para la carrera de ascenso (corrida de extracción), se acciona la válvula del winche, se levanta la palanca de freno para liberar zapatas del ring brake, y se comienza el enrollamiento.
- Cuando la columna de fluido está por llegar a la superficie, se disminuye la velocidad de ascenso del conjunto de SW.

f) Desmontaje del equipo

- Luego de haber concluido con la intervención de un pozo, se desconecta la manguera del tanquero o carreta
- Se levanta tubo lubricador y se retira la porta copa con su copa.
- En caso de haber botado la herramienta al pozo (standing valve viajero) se coloca el pescante, se realiza la pesca de la herramienta, y se sigue con la operación.
- El asistente u operador guían el tubo lubricador y lo asientan sobre su base y se enrosca la unión de golpe.
- Se retira el seguro de base de la pluma, se acciona el mando hidráulico para tumbar la pluma, se inclina y el ayudante acomoda el tubo lubricador sobre sus guías.
- Se continúa el descenso de la pluma, hasta asentar la pluma en su base, teniendo en cuenta de no aplastar el cable con la misma, seguidamente, se levantan las patas de la unidad
- Se retira las reducciones que se usaron, se recogen las llaves utilizadas y se las guarda en la caja de herramientas.
- Antes de abandonar el pozo, para dirigirse al siguiente pozo del programa, se debe inspeccionar el entorno, dejando la locación limpia después de cada intervención.

g) Equipos en superficie y subsuelo del sistema SW. Está formado por todos los componentes y accesorios que se utilizan durante la realización de la operación de Pistoneo. Estos componentes y accesorios se pueden clasificar como: de superficie y de subsuelo.

El equipo de superficie incluye:

- Equipo de SW.
- Lubricador hidráulico.
- Tubo lubricador.
- Bomba hidráulica manual
- Árbol de pistoneo con bandeja colectora de fluidos.
- Manguera de producción
- Reducciones de 2 3/8" a 2 7/8", 2 3/8" a 2"
- Martillo de bronce.
- Manguera de bomba hidráulica

El equipo de subsuelo incluye:

- Cable de acero
- Guardacabo.
- Unión giratoria (Swivel)
- Varillón.
- Caja o zapato.

- Mandril (Porta Copas)
- Copa de SW.
- Válvula de retención de fondo (Standing valve)
- Standing viajero de 2 3/8" y 2 7/8"

h) Ventaja

- Standing fijo en el pozo ahorra tiempo de operación.
- No necesita instalación de tubing de producción de 2 3/8" o 2 7/8"
- Tiene flexibilidad para adaptarse a los cambios de caudales en las arenas productoras.
- Operación de bajo riesgo, en caso de un posible problema de agarre del conjunto se saca la tubería, se recupera el conjunto y se reinstala la tubería

i) Desventajas

- Pozos sin standing fijo pérdida en tiempo porque se lanza por caída libre y después es necesario realizar pesca.
- Para evaluar el pozo se requiere baja tubería, lo cual representa un gasto adicional.
- Desgastes rápidos de las copas de succión.
- Riesgo de contaminación.
- Costos altos de mantenimiento y reparación
- Daños continuos en el lubricador hidráulico

2.3.3 Herramienta local



Figura 15. SLA por HL (García & Villón, 2014)

- a) **Generalidades del sistema.** El método más sencillo y utilizado por su bajo costo de operación y rápida recuperación de producción en el proceso de extracción de crudo en el Campo Ancón es el sistema de **HL**. (García & Villón, 2014)

Es una técnica de extracción de fluidos del interior de un pozo, desde una profundidad dada hacia la superficie por medio de un barril con válvula (botella) que es introducida en el pozo. Esta operación se realiza debido a que la presión de la formación del pozo no es lo suficientemente mayor para vencer la columna hidrostática que existe y poder expulsar el líquido drenado a superficie. El drenaje de estos pozos es muy lento con respecto al tiempo. Para hacer producir estos pozos, se utiliza cable de acero, que va enrollado en el winche; y con ayuda de otros componentes y accesorios de subsuelo, se hace posible la recuperación de fluidos. (García & Villón, 2014)

b) ***Procedimiento operativo*** El camión o unidad móvil se ubica en una posición adecuada para tener una buena operación, y se estabiliza mediante dos gatos de accionamiento hidráulico. La botella se sumerge en el casing por gravedad hasta alcanzar el nivel de fluido en el fondo; la válvula inferior se abre e ingresa el petróleo hasta que la botella se llene. Luego, la botella es levantada mediante la tracción generada por el motor auxiliar y la válvula se cierra por el peso del fluido, llega a la superficie y se descarga el crudo en un embudo que lo canaliza a un tanque de almacenamiento adaptado a la unidad. Este proceso se repite varias veces hasta lograr recuperar la producción acumulada en el fondo del pozo. ***(Ricardo, 2013)***

c) ***Problemas operacionales*** El principal problema que se presenta en este SLA es el atascamiento de botella en el pozo la cual se presenta por rotura de cable desgastado por; sumergirse en residuos o lodo en el fondo del pozo, casing colapsado, mal manejo de los operadores en la unidad. Estos problemas generan un alto costo de operación por intervención al pozo por servicio de pulling; este SLA es costoso en el campo GGV por consumo de combustibles. ***(Ricardo, 2013)***

d) ***Armada de equipo***

- Bajar botella calculando el nivel de fluido (fondo)
- Marcar en el cable distancia de profundidad
- Posicionar la botella en profundidad para primera extracción
- Calcular el tiempo de llenado de la botella
- Levantar la botella a superficie (corrida de extracción)
- Direccionar la botella en superficie hacia el tanque receptor
- Continuar el ciclo hasta que disminuya el nivel

e) *Desmontaje:*

- Se libera el seguro de mástil.
- Bajar el cuerpo (mástil).
- Disponer la botella en soporte.
- Apagar el motor auxiliar.
- Desactivar anclajes.
- Taponar la cabeza del pozo.
- Recoger las herramientas utilizadas.
- Retirar la Unidad de locación.

f) *Equipos de superficie y subsuelo.* El equipo de HL está formado por todos los componentes y accesorios que se utilizan durante la realización de la operación de extracción. Estos componentes y accesorios se pueden clasificar como: de superficie y de subsuelo. (*García & Villón, 2014*)

Equipos de subsuelo

- Cable de acero.
- Guardacabo.
- Unión giratoria.
- Cupla y reducción de 3/4".
- Botella de 3", botella de 4" y botella de 6 5/8".

Equipo de superficie

- Equipo camión de HL
- Tanque: Sirve para almacenar el fluido recuperado desde el pozo
- Tanque de recobro: Sirve para almacenar el fluido recuperado desde el pozo.
- Motor: Es el que genera el movimiento y la fuerza para el mecanismo movimiento del malacate.
- Malacate: Es un tambor que hace la función de sostener el cable de acero, y darle el mecanismo de levantamiento al fluido dentro del pozo.

g) Ventaja

- Fácil operación.

h) Desventajas

- Derrame de petróleo, contaminación de suelo.
- Alto costo de operación.
- Intervención del pozo necesita factor humano de operadores para operación y servicio.
- Costos altos de mantenimiento y reparación.

2.4 APRENDIZAJE POR COMPUTADOR

2.4.1 Descripción

La inteligencia artificial se define como "La ciencia y la ingeniería de hacer máquinas inteligentes. Está relacionado con la tarea similar de usar computadoras para comprender la inteligencia humana, pero la IA no tiene que limitarse a métodos que son biológicamente observables". Ver Figura 16 (Alandete, 2011)

Francois Chollet, investigador de IA en Google y creador de la biblioteca de software de aprendizaje automático Keras, coincide en que la inteligencia está ligada a la capacidad de un sistema para adaptarse e improvisar en un nuevo entorno, para generalizar su conocimiento y aplicarlo a escenarios desconocidos. (Julia, 2021)

Sí pareciera haber un acuerdo acerca de la capacidad transformadora de la IA. Andrew Ng4 la define como la nueva electricidad, por su capacidad de transformar todas las industrias, de la misma manera que lo hizo la electricidad hace cien años. (Ng, 2019)

Kaplan y Haenlein definen la IA como "la capacidad de un sistema para interpretar correctamente datos externos, aprender de dichos datos y utilizar esos aprendizajes para lograr objetivos y tareas específicos mediante una adaptación flexible" (Kaplan & Haenleinb, 2019)

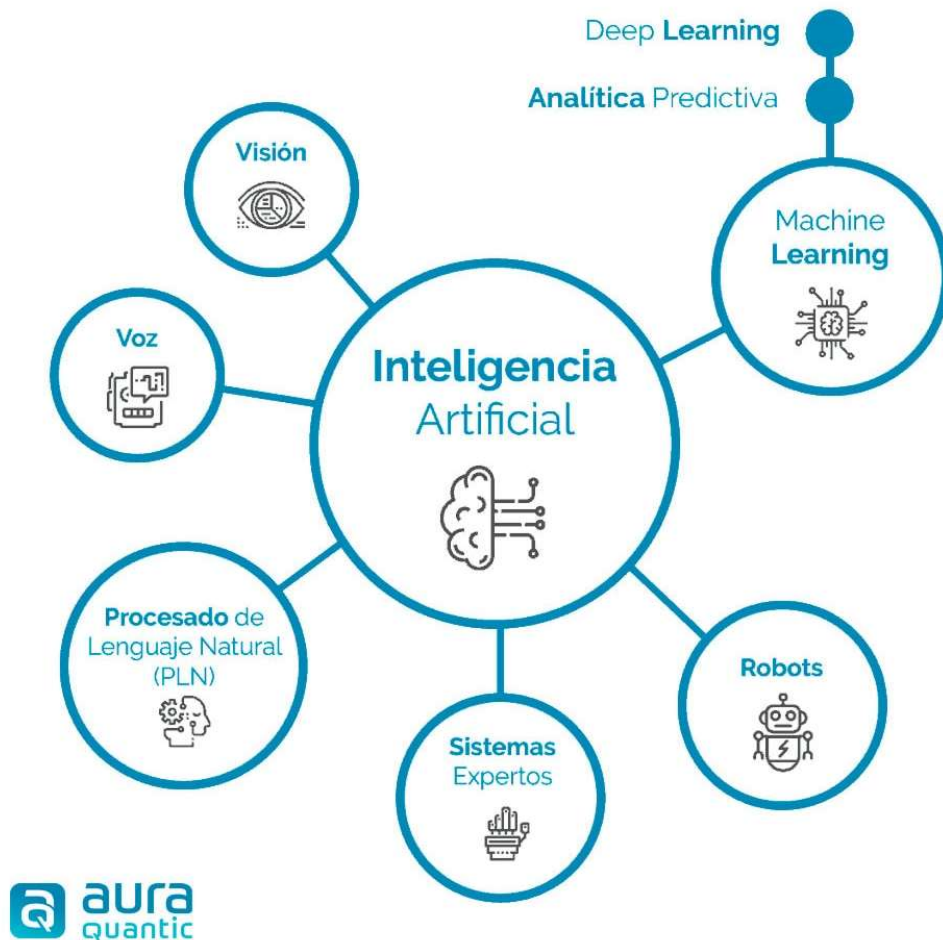


Figura 16. IA y categorías relacionadas (Mauro, 2021)

2.4.2 Historia

El término IA se acuñó en 1956, pero la IA ha evolucionado desde sus humildes comienzos hasta un campo con impacto global, gracias al aumento en los volúmenes de datos, los algoritmos avanzados y las mejoras en la capacidad de procesamiento y el almacenaje.

Las primeras investigaciones sobre IA corresponden de la década de 1950 con el Precursor de la informática moderna Alan Turing ver Figura 17, donde se exploraron temas como la solución de problemas y los métodos simbólicos. Más tarde, Alan Turing sugirió que podría ser posible determinar si una máquina es inteligente en función de su capacidad para exhibir un comportamiento inteligente. Publicado mediante un artículo en la revista de filosofía *Mind*, titulado “Maquinaria de computación e inteligencia”, en el que escribió: “Creo que aproximadamente en los próximos cincuenta años será posible programar computadoras para que puedan desarrollar el juego de imitación tan bien que un interrogador medio no tendrá más del 70% de probabilidades de realizar la identificación correcta después de 5 minutos de preguntas. Sobre la cuestión inicial, ‘¿Pueden pensar las máquinas?’’, creo que no posee el suficiente sentido como para que merezca discutirse. Sin embargo, pienso que al final del siglo el uso de palabras y de opiniones razonadas de tipo general se habrá modificado tanto que uno podrá hablar de máquinas que piensan sin esperar que le contradigan”. (Sánchez Ron , 2015)

En la década de 1960, el Departamento de Defensa de EE. UU se interesó en este tipo de trabajo y comenzó a entrenar computadoras para imitar el razonamiento humano básico. Por ejemplo, la Agencia de Proyectos de Investigación Avanzada de Defensa (DARPA) completó proyectos de planimetría en la década de 1970. Y DARPA produjo asistentes personales inteligentes en 2003, mucho antes de que Siri, Alexa o Cortana fueran nombres familiares. (Goodnight, 2021)

El año 1997 es considerado por algunos historiadores de la IA como el punto de inflexión donde comenzó a oírse de la IA fuera de los ámbitos académicos y de investigación. En ese año, la supercomputadora Deep Blue, creada por IBM, vence al campeón del mundo de ajedrez Gary Kasparov. En el 2012, se conoce el verdadero poder del Deep learning donde Google crea un superordenador capaz de aprender a través de

YouTube a identificar gatos, así como caras y cuerpos humanos. Y en octubre del 2015 AlphaGo se convirtió en la primera máquina en ganar a un jugador profesional de Go sin emplear piedras de hándicap en un tablero de 19x19. (Geographic, 2019)



Figura 17. Estatua de pizarra de Alan Turing en Bletchley Park (Call, 2015)

2.4.3 Machine learning

- a) **Definición de machine learning.** El Aprendizaje automático es un subcampo de la IA centrado en un conjunto de técnicas que permite a las máquinas aprender automáticamente, sin ser programadas explícitamente. El Aprendizaje automático está basado en la creación de algoritmos que aprenden iterativamente dentro de grandes conjuntos de datos (conocido como dataset), a través de un entrenamiento, detectando patrones en los datos y luego adquirir experiencia permitiéndole usar los patrones descubiertos para predecir resultados sin la ayuda de seres humanos. Sin embargo, el aprendizaje automático no es un proceso sencillo, ya que requiere específicamente de información histórica recolectada para describir mejor los datos y en base al conocimiento adquirido mejorar el desempeño de las predicciones, minimizando el error.

Arthur Samuel definió el aprendizaje automático como “El campo de estudio que da a las computadoras la capacidad de aprender sin enseñarles explícitamente”. (Oliveira, 2017)

Tom Mitchell define el aprendizaje automático como “El estudio de algoritmos de computación que mejoran automáticamente su rendimiento gracias a la

experiencia. Se dice que un programa informático aprende sobre un conjunto de tareas, gracias a la experiencia y usando una medida de rendimiento, si su desempeño en estas tareas mejora con la experiencia.” Ver Figura 18 (Mitchell, 1997)




Figura 18. Machine learning subcampo de la IA (Alonso, 2020)

b) Tipos de aprendizaje. El área del aprendizaje automático se divide en subáreas según los tipos de problemas que se presentan. Los algoritmos de Machine Learning se dividen en tres categorías ver Figura 19, siendo las dos primeras las más comunes:

- **Aprendizaje Supervisado:** estos algoritmos cuentan con un aprendizaje previo basado en un sistema de etiquetas asociadas a unos datos que les permiten tomar decisiones o hacer predicciones. Es decir, se nos da un conjunto de datos y ya sabemos cómo debería ser nuestra salida correcta, teniendo la idea de que existe una relación entre la entrada y la salida.

Los problemas de aprendizaje supervisado se clasifican en:

- **Clasificación:** En un problema de clasificación, en cambio, estamos tratando de predecir los resultados en una salida discreta y son interpretadas como la clase a la que pertenece.
 - **Regresión:** En un problema de regresión, estamos tratando de predecir resultados dentro de una salida continua, lo que significa que estamos tratando de asignar variables de entrada a alguna función continua.
-
- **Aprendizaje no supervisado:** estos algoritmos no cuentan con un conocimiento previo, nos permite abordar los problemas con poca o ninguna idea de cómo deberían verse nuestros resultados. Podemos derivar la estructura de los datos en los que no necesariamente conocemos el efecto de las variables. Podemos derivar esta estructura agrupando los datos en función de las relaciones entre las variables en los datos. Con el aprendizaje no supervisado, no hay retroalimentación basada en los resultados de la predicción.
 - **Aprendizaje por refuerzo:** estos algoritmos aprenden a partir de la propia experiencia. En este caso, que sea capaz de tomar la mejor decisión ante diferentes situaciones de acuerdo con un proceso de prueba y error con el objetivo de que el algoritmo aprenda las consecuencias de sus decisiones.

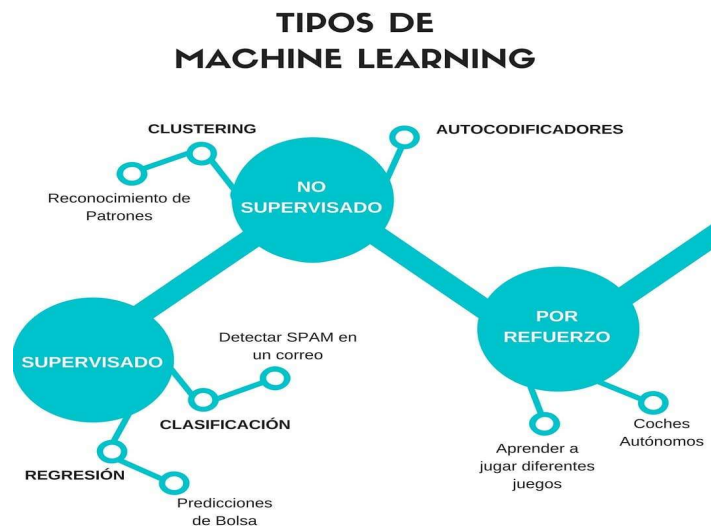


Figura 19. Los Tipos de Aprendizaje Automático (Sanseviero, 2018)

- c) **Flujo de trabajo de Machine Learning.** Un sistema de aprendizaje automático está entrenado en lugar de programado explícitamente, para aquello se propone un flujo de trabajo universal que contiene 7 fases, pertenecientes al libro “Deep Learning con Python” del autor Francois Chollet. Ver Figura 20
- **Dataset:** El elemento principal y de mayor importancia es el conjunto de datos y si no se cuenta con una gran cantidad de muestras, difícilmente se podrá realizar el estudio o proyecto.
 - **Visualización de Datos:** Generalmente se depuran los datos que no se relacionan a los objetivos propuestos para el estudio o proyecto.
 - **Preprocesamiento de los datos:** Se analizan los datos de entrenamiento y se deben dominar conceptualmente los algoritmos estudiados en el Machine Learning y detectar que tipos de entrada de datos reciben, que resultados generan y que tipo de tareas resuelven.
 - **Entrenamiento de los datos:** Seleccionado el algoritmo analizado en base a su velocidad de entrenamiento, uso de memoria, precisión predictiva y transparencia, las máquinas ajustarán los parámetros del modelo matemático, para poder en el futuro tomar decisiones por sí mismas. El formato del algoritmo debe contener variables de entrada y de salida, colocar los datos en formas matriciales, crear categorías binarias, y partir y aleatorizar las muestras.
 - **Ajustar el modelo:** La función del ajuste dependerá del algoritmo elegido, se normalizan los datos de prueba
 - **Prueba del algoritmo:** Evaluar correctamente el modelo y asegurar que funcionará con datos nuevos. Se considera la fase más larga y donde se juega con el ensayo y error.
 - **Interpretación y evaluación de los Resultados.**

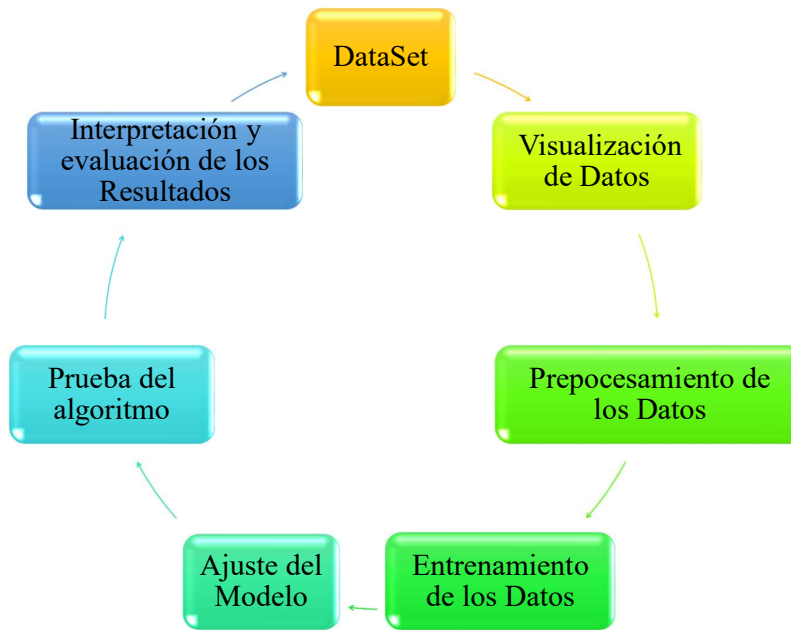


Figura 20. Flujo de trabajo de Machine Learning

d) **Técnicas de machine learning.** A continuación, se presenta una lista de los algoritmos de aprendizaje automático supervisado:

- Árboles de decisión
- Árboles de Clasificación y Regresión (CART)
- Naive Bayes
- Gaussian Naive Bayes
- Multinomial Naive Bayes
- Bayesian Network
- Regresión ordinaria por mínimos cuadrados
- Regresión Lineal
- Regresión logística multinomial (MLR)

- k-Nearest Neighbor (kNN)
- Máquinas de soporte vectorial (SVM)
- Métodos de conjunto
- Red neuronal de propagación hacia atrás (BPNN)

También se tiene la lista de los algoritmos de aprendizaje automático no supervisado:

- Algoritmos de Clustering (Agrupación)
- K-Means
- K-Medians
- Hierarchical Clustering
- Reducción de dimensión
- Algoritmos basados en conectividad
- Probabilísticos
- Análisis de Componentes Principales (PCA)
- Singular Value Decomposition (SVD)
- Análisis de Componentes Independientes (ICA)

El algoritmo de aprendizaje reforzado:

- Q-Learning
- Algoritmos Généricos

- Deep Q-Network (DQN)
- SARSA
- ASC

A continuación, para una mejor comprensión, describir en qué consiste el algoritmo seleccionado para realizar el estudio:

El algoritmo árbol de decisión es un modelo predictivo que divide el espacio de los predictores agrupando observaciones con valores similares para representar los posibles resultados que ocasionaría la toma de una decisión. Convirtiéndose en una herramienta de apoyo en eventualidades que se presenten, como los costos de recursos y la utilidad.

Para dividir el espacio muestral en subregiones es preciso aplicar una serie de reglas o decisiones, para que cada subregión contenga la mayor proporción posible de individuos de una de las poblaciones.

Si una subregión contiene datos de diferentes clases, se subdivide en regiones más pequeñas hasta fragmentar el espacio en subregiones menores que integran datos de la misma clase.

El algoritmo de árbol de decisión genera un modelo de minería de datos mediante la creación de una serie de divisiones similares a un diagrama de flujo. Estas divisiones se representan como nodos. El algoritmo agrega un nodo al modelo cada vez que una columna de entrada tiene una correlación significativa con la columna de predicción. La forma en que el algoritmo determina una división varía en función de si predice una columna continua o una columna discreta. Se utiliza la selección de características para guiar la selección de los atributos más útiles, donde cada nodo representa una prueba en una variable específica y las ramas representan los resultados. Ver Figura 21

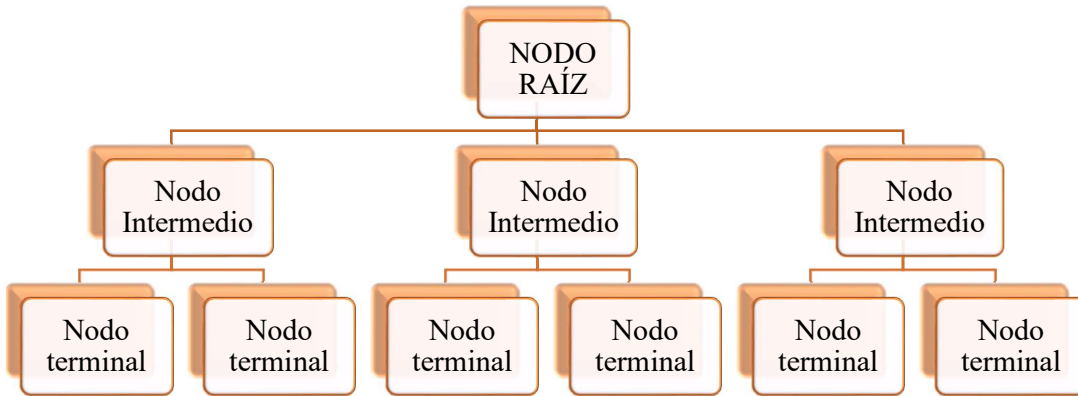


Figura 21. Los árboles de decisión están formados por nodos. (Merayo, 2020)

Los métodos basados en árboles de decisiones potencian los modelos predictivos con alta precisión, estabilidad y facilidad de interpretación

- El algoritmo Iterative Dichotomizer 3 (ID3) fue inventado por Ross Quinlan y hasta el momento es el algoritmo más utilizado en arboles de decisión y consiste en la construcción de un árbol de decisión de arriba a abajo, de forma directa, sin hacer uso de backtracking, y basándose únicamente en los ejemplos iniciales proporcionados. Para seleccionar los criterios de decisión se considera el concepto de error de Clasificación, el índice Gini y la Entropía.
- El error de clasificación de acuerdo con la ecuación (2) es una medida de la discrepancia entre los datos reales y los predichos por el modelo. Como indicador se tiene que a menor RSS hay un buen ajuste del modelo a los datos.

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

y_i = es el valor real de la variable a predecir

\hat{y}_i = es el valor predicho

- El índice Gini de acuerdo con la ecuación (3) mide el grado de pureza de un nodo permitiendo separar mejor los ejemplos respecto a la clasificación final. Como indicador se tiene que a mayor índice de Gini menor pureza, por lo que seleccionaremos la variable con menor Gini ponderado.

$$RGINI(t) = 1 - \sum_{i=1}^n (P_i)^2 \quad (3)$$

$P_i =$ Probabilidad de que un ejemplo sea de la clase i

- La entropía de acuerdo con la ecuación (4) mide el grado de incertidumbre de una muestra. Es directamente proporcional con el índice Gini ya que ha mayor ganancia de información menor entropía ponderada de la variable. Como indicador si un nodo es puro su entropía es 0 y solo tiene observaciones de una clase, pero si la entropía es igual a 1, existe la misma frecuencia para cada una de las clases de observaciones.

$$H = - \sum_{i=1}^n P_i * \log_2 P_i \quad (4)$$

$P_i =$ Probabilidad de que un ejemplo sea de la clase i

- e) Aplicación del machine learning en la industria del petróleo y gas.** Después de un comienzo lento, la industria del petróleo y gas parece estar ansiosa por adoptar todo tipo de tecnología digital, ya que ayuda a las compañías a mantener los costos bajos y al mismo tiempo aumenta la eficiencia. Por lo que optan por actualizar sus esquemas mediante el aprendizaje automático.

A continuación, mostraremos las aplicaciones que ha tenido el aprendizaje automático en este sector competitivo.

- Estudios sísmicos
- Registros de pozos
- Diferenciación de equipos debido a sus características (profundidad, almacenamiento, potencia)
- Planillas de consumo de combustible
- Curvas de planificación de la actividad en el pozo

- Planillas de maniobras diarias
- Análisis de fluidos
- Mediciones de presión estática y de flujo
- Pruebas de presión transitoria
- Pruebas periódicas de producción de pozos
- Registros de los volúmenes mensuales de fluidos producidos (petróleo, gas y agua)
- Registros de los volúmenes mensuales de fluidos inyectados (agua, gas, CO₂, vapor, productos químicos), entre muchos otros.
- Predice rendimiento del reservorio
- Optimizar la configuración de perforación
- Mejorar la planificación de pozos
- Asegurar las operaciones de los ductos
- Reducir costos de mantenimiento
- Reducir costos operativos
- Mejora la producción de Campo
- Sensores bajo demanda
- Manejo de eventos

2.5 HERRAMIENTA PARA VIABILIDAD

2.5.1 Valor actual neto.

El valor actual neto (VAN) o también denominado como valor presente neto se define como la diferencia entre los ingresos y egresos representados al precio actual en el que se calcula los ingresos que va generar la implementación de un proyecto a lo largo de su vida útil, es decir, se considera como ayuda en la generación de criterios para la toma de decisión al momento de aplicar o no un proyecto, para aquello se tiene la siguiente condición: si el resultado VPN, es positivo, se deberá aceptar el proyecto y si el resultado es negativo, el proyecto se deberá rechazar.

El cálculo del VPN se realiza, mediante, la siguiente ecuación (5):

$$\text{Valor actual neto} = \frac{Fi}{(1 + k)^n} \quad (5)$$

$n = \text{Número de periodo}$

$k = \text{Tasa de interés}$

$Fi = \text{Flujo de Caja}$

CAPÍTULO III: METODOLOGÍA

3.1 METODOLOGÍA DE LA INVESTIGACIÓN

3.1.1 Tipo de investigación.

El presente trabajo se basa en una investigación descriptiva, cuantitativa y comparativa de los diferentes métodos de levantamiento artificial con los que se está produciendo en el campo GGV “sección 66”.

3.1.2 Recopilación de datos e información.

La investigación teórica es necesaria para la recopilación de información sobre los SLA por BM, HL y Pistoneo o SW.

Para conocer los diferentes estudios que se han realizado referentes a la selección óptima de un SLA se requiere de una investigación bibliográfica, en la cual se obtiene información sobre análisis de SLA y conceptos de producción de pozos en función de caudal y presión. Revisar publicaciones de (Beggs, 2003).

Actividades para llevar a cabo el desarrollo del tema propuesto:

- Un análisis cualitativo de cada uno de los SLA que son utilizados en el área de estudio en función de las diferentes características y generalidades que presentan.

- El uso de un algoritmo de machine learning el cual analizará todos los datos recolectados en el área de estudio: historial de producción, costos operativos y de mantenimiento, gravedad API, ciclos, número de intervenciones.
- Analizar el resultado obtenido del algoritmo con respecto a la selección del SLA óptimo.
- Calcular la factibilidad económica del proyecto en base al análisis de los pozos con mayor producción diaria.

3.1.3 Población y muestra

La población es la sección 66 del campo GGV ubicado en la provincia de Santa Elena– Ecuador

La muestra depende: la ubicación de cada uno de los pozos, el SLA con que operan actualmente y el estado en el que se encuentran (productores, parados-transitorios, inyectoros).

3.1.4 Procesamiento de Información

Los datos e información se representan en tablas e ilustraciones en Excel, además del uso de un algoritmo de machine learning para ejecutar y validar los datos obtenidos durante el levantamiento de información.

3.2 METODOLOGÍA DE ANÁLISIS

3.2.1 Criterios para la selección del SLA óptimo a implementar en la sección 66

- a) **Rango de profundidad.** A continuación, se muestran los rangos de profundidad. Los valores de profundidad varían dependiendo de la región en que se encuentre la formación productora, el rango que indican las siguientes tablas son de 2802’ – 5209’ correspondiente al sistema por BM, el método de HL es de 806’ – 4190’ y 910’ – 5423’ para el sistema por Pistoneo. Ver Tabla 10, Tabla 11 y Tabla 12

Tabla 10. Profundidad de los pozos que operan con SW o Pistoneo (Pacifpetrol, 2021)

Nombre de pozo	Profundidad (ft)
ANC0162	910
ANC0163	3200
ANC0589	4984
ANC0655	3425
ANC1493	1013
ANC1648	5423
ANC1678	1138
ANC3007	3800

Tabla 11. Profundidad de los pozos que operan con BM (Pacifpetrol, 2021)

Nombre de pozo	Profundidad (ft)
ANC0437	4000
ANC0446	3800
ANC0458	3844
ANC0461	2832
ANC0465	3507
ANC0504	4000
ANC0508	3850
ANC0585	3570
ANC0656	3328
ANC0778	5209

Tabla 12. Profundidad de los pozos que operan con HL (Pacifpetrol, 2021)

Nombre de pozo	Profundidad (ft)
ANC0420	3500
ANC0424	3765
ANC0434	3900
ANC0582	3368
ANC0667	4190
ANC1073	806

Tabla 13. (Continuación)

ANC1393	1655
ANC1395	1350
ANC1396	1300
ANC1703	1500
ANC1713	1650
ANCFA02	1787
ANCFA13	1994
ANCFA22	1966

b) Tipo de fluido. El petróleo es clasificado en liviano, mediano, pesado y extrapesado de acuerdo con su medición °API, que diferencia las calidades de crudo. Ver Tabla 14, Tabla 15, Tabla 16 y Tabla 17. Los grados ° API se definen como:

Tabla 14. Clasificación del petróleo según los grados API (Pacifpetrol, 2021)

Clasificación del petróleo	°API
Ligero o liviano	≥31.1
Mediano	22.3-31.1
Pesado	10-22.3
Extrapesado	<10

Tabla 15: Grados API del fluido de los pozos que producen con SW o Pistoneo (Pacifpetrol, 2021)

Nombre de pozo	°API
ANC0162	38,3
ANC0163	37,8
ANC0589	40,1
ANC0655	37,2
ANC1493	38,6
ANC1648	39,6
ANC1678	43,5
ANC3007	38,4

Tabla 16: Grados API del fluido de los pozos que producen con BM (Pacifpetrol, 2021)

Nombre de pozo	°API
ANC0437	36,6
ANC0446	40
ANC0458	36,6
ANC0461	39,6
ANC0465	39,8
ANC0504	39,8
ANC0508	37,5
ANC0585	38,9
ANC0656	38,1
ANC0778	39

Tabla 17: Grados API del fluido de los pozos que producen con HL (Pacifpetrol, 2021)

Nombre de pozo	°API
ANC0420	38,5
ANC0424	35
ANC0434	38,7
ANC0582	39,4
ANC0667	42,6
ANC1073	40,7
ANC1393	38,3
ANC1395	38,7
ANC1396	40,2
ANC1703	38
ANC1713	38,7
ANCFA02	42,6
ANCFA13	41,4
ANCFA22	38,7

- c) **Producción diaria.** A continuación, se muestran los datos de la producción diaria promedio de los pozos con su respectivo SLA. Ver Tabla 18, Tabla 19 y Tabla 20.

Tabla 18. Producción promedio diaria de los pozos que operan por SW (Pacifpetrol, 2021)

Nombre del pozo	Producción diaria (bpd)
ANC0162	0,61
ANC0163	1,43
ANC0589	1,87
ANC0655	0,94
ANC1493	0,70
ANC1648	0,93
ANC1678	0,47
ANC3007	0,91

Tabla 19. Producción promedio diaria de los pozos que operan por BM (Pacifpetrol, 2021)

Nombre del pozo	Producción diaria (bpd)
ANC0437	0,46
ANC0446	1,83
ANC0458	0,92
ANC0461	1,43
ANC0465	4,66
ANC0504	3,85
ANC0508	0,96
ANC0585	3,04
ANC0656	0,96
ANC0778	2,51

Tabla 20. Producción promedio diaria de los pozos que operan por HL (Pacifpetrol, 2021)

Nombre del pozo	Producción diaria (bpd)
ANC0420	0,23
ANC0424	0,24
ANC0434	0,24
ANC0582	0,12

Tabla 21. (Continuación)

ANC0667	0,23
ANC1073	0,69
ANC1393	0,16
ANC1395	0,06
ANC1396	0,12
ANC1703	0,32
ANC1713	0,23
ANCFA02	0,62
ANCFA13	0,03
ANCFA22	0,46

d) Gastos promedio de los SLA. A continuación, se muestran los gastos promedios mensuales que genera la extracción del crudo y el mantenimiento de los SLA por cada pozo. Ver Tabla 22, Tabla 23, Tabla 24 y Figura 22

Tabla 22. Gasto promedio mensual del SLA SW (por cada pozo) (Pacifpetrol, 2021)

Ítems	Descripción	Monto
Extracción del crudo	Combustible	336,20
	Grasas y lubricantes	49,49
Mantenimiento de la unidad	Mantenimiento de equipos	445,79
TOTAL		831,48

Tabla 23. Gasto promedio mensual del SLA BM (por cada pozo) (Pacifpetrol, 2021)

Ítems	Descripción	Monto
Extracción del crudo	Combustible	16,11
	Grasas y lubricantes	25,69
Mantenimiento de la unidad	Mantenimiento de equipos	60,26
TOTAL		102,06

Tabla 24. Gasto promedio mensual del SLA HL (por cada pozo) (Pacifpetrol, 2021)

Ítems	Descripción	Monto
Extracción del crudo	Combustible	99,79
	Grasas y lubricantes	21,87
Mantenimiento de la unidad	Mantenimiento de equipos	251,48
TOTAL		373,14

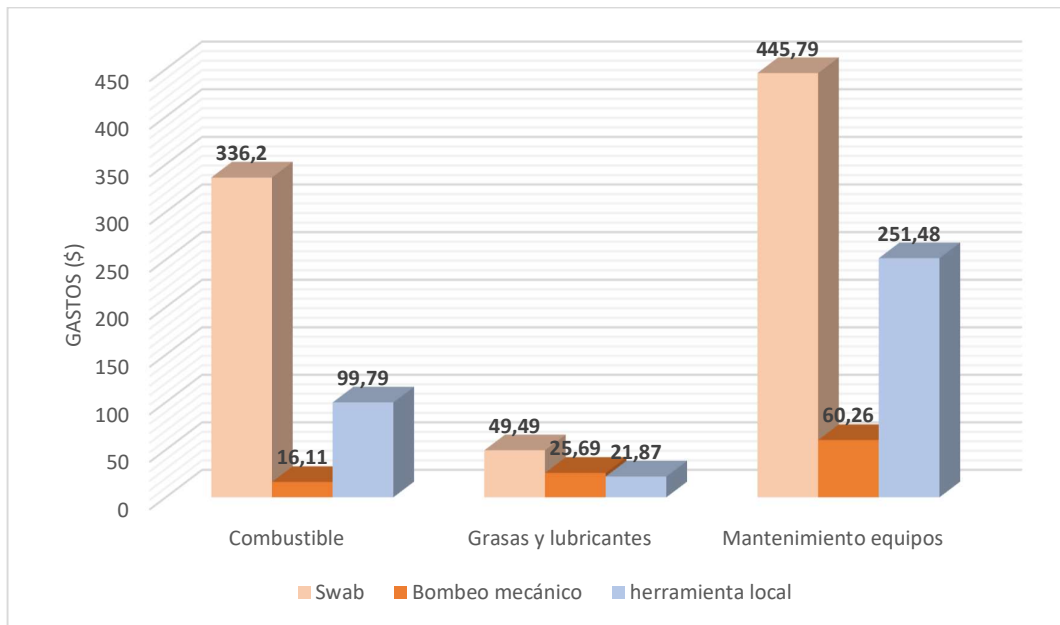


Figura 22. Gastos mensuales que genera cada SLA en un pozo (Pacifpetrol, 2021)

3.3 ESTRUCTURACIÓN DE ALGORITMO

Para el desarrollo del algoritmo se necesita instalar Python como se muestra en Anexo A. Crear un notebook como se muestra en la Figura 23, se observa una interfaz con un menú de herramientas y un área de trabajo que contiene celdas donde se escribe texto o código. Ver Anexo H.

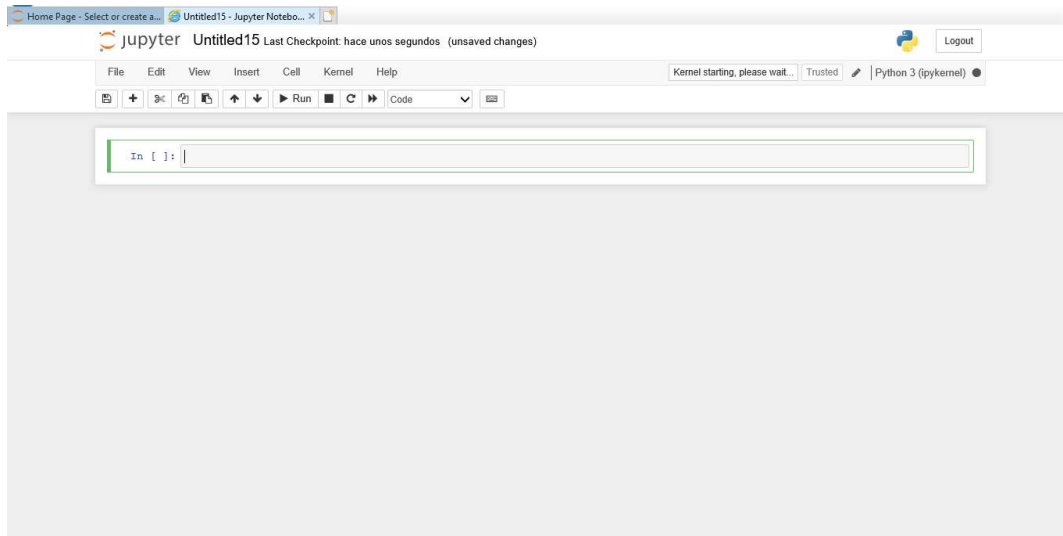


Figura 23. Área de trabajo en notebook

Para escribir el código en la primera celda, seleccionar “Code” que se ubica en la parte superior de la barra de herramienta, clic en la celda e importar las librerías anteriormente instaladas, una vez importada la librería ejecutar el código y avanzará automática al siguiente bloque. Ver Figura 24

IMPORTAR LIBRERÍA

```
In [1]: import pandas as pd
import numpy as np
import seaborn as sns
import graphviz
import matplotlib.pyplot as plt
import matplotlib.image as pltimg
import pydotplus
from sklearn import tree
from sklearn import metrics
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import accuracy_score, r2_score
from sklearn.metrics import classification_report
from sklearn.metrics import confusion_matrix
from sklearn.tree import export_graphviz
from sklearn.model_selection import cross_val_score
from sklearn.preprocessing import LabelEncoder
from IPython.display import Image
import plotly.express as px
```

Figura 24. Importar librería

Lectura del archivo Excel con extensión xlsx que contiene datos que se obtuvieron del levantamiento de información, para esto se debe colocar el archivo en la misma ubicación donde se tiene instalado el programa Python. Al especificar la función de lectura facilita la carga del archivo. Ver Figura 25

LECTURA DE DATASET

```
In [2]: TESIS_UPSE = pd.read_excel("info_pozosDT.xlsx")
        TESIS_UPSE
```

```
Out[2]:
```

	Pozos	Profundidad verdadera (ft)	Formación productora	Reserva de la formación (mmbis)	Gravedad API	Temperatura observada (°f)	Salinidad (ppm)	Ciclos	Producción acumulada (bppd)	Gasto en combustible (\$)	Gasto en grasas y lubricantes (\$)	Gasto en Mantenimiento de equipo (\$)	Número intervencion
0	ANC0162	910	CPB	2.33	38.3	71	18662	3	1095.00	16551.600	2526.60	15554.280	
1	ANC0163	3200	AT	73.53	37.8	72	29647	2	2573.25	18206.760	3031.92	16665.300	
2	ANC0589	4984	AT	73.53	40.1	77	26892	8	3358.00	26151.528	3542.56	44440.800	
3	ANC0655	3425	AT	72.53	37.2	82	27555	7	1697.25	24827.400	3031.92	17776.320	
4	ANC1493	1013	CPB	2.33	38.6	78	24025	4	1259.25	18537.792	3284.58	46662.840	
5	ANC1648	5423	AT	73.53	39.6	75	28498	6	1679.00	19034.340	3789.90	15776.484	
6	ANC1678	1138	CPB	2.33	43.5	83	24922	4	848.62	13241.280	1263.30	13776.648	
7	ANC3007	3800	AT	73.53	38.4	71	11975	3	1642.50	24827.400	3284.58	43329.780	
8	ANC0420	3500	AT	73.53	38.5	79	26905	12	415.18	5274.000	1359.00	14913.600	
9	ANC0424	3765	AT	73.53	35.0	71	11055	8	424.31	5326.740	1494.90	16404.960	
10	ANC0434	3900	AT	73.53	38.7	71	21615	6	428.87	5379.480	1630.80	15211.872	
11	ANC0582	3368	AT	73.53	39.4	80	15866	12	209.87	2637.000	815.40	7456.800	
12	ANC0667	4190	AT	73.53	42.6	77	14922	25	416.10	5353.110	1386.18	15137.304	
13	ANC1073	806	CPB	2.33	40.7	72	12289	2	1245.56	14767.200	2582.10	22370.400	
14	ANC1393	1655	CPB	2.33	38.3	74	17325	12	288.95	3111.660	543.60	8799.024	

Figura 25. Lectura del archivo *xlsx*

El dataframe contiene una gran cantidad de columnas en el que normalmente solo se muestran algunas, para aquello se procede a visualizar todas las columnas del dataframe y renombrar el formato de las variables ya que Python no reconoce cadenas de texto con espacio y al continuar con el desarrollo del algoritmo sin transformar el formato presentaría errores al momento de ejecutar. Ver Figura 26

- Mostrar las columnas del Dataframe

```
In [3]: TESIS_UPSE.columns=("Nombre_pozo","Profundidad","fm_productora","Reserva_fm","Gravedad_API","Temperatura","Salinidad","Ciclos",
        TESIS_UPSE.columns

Out[3]: Index(['Nombre_pozo', 'Profundidad', 'fm_productora', 'Reserva_fm',
              'Gravedad_API', 'Temperatura', 'Salinidad', 'Ciclos',
              'Producción_acumulada', 'Gasto_combustible', 'Gasto_grasas',
              'Gasto_mant', 'N_intervenciones', 'cambios_sla_en_5_años',
              'Gasto_total', 'SLA'],
              dtype='object')
```

Figura 26. Visualización y modificación del formato de variables

El algoritmo interpreta los datos con el fin de conocer que en las variables que tienen datos numéricos no pueden existir datos de texto y viceversa, puesto que generaría un error. Ver Figura 27

- Tipo de data

```
In [4]: TESIS_UPSE.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 32 entries, 0 to 31
Data columns (total 16 columns):
#   Column                Non-Null Count  Dtype
---  ---
0   Nombre_pozo           32 non-null     object
1   Profundidad           32 non-null     int64
2   fm_productora         32 non-null     object
3   Reserva_fm            32 non-null     float64
4   Gravedad_API          32 non-null     float64
5   Temperatura           32 non-null     int64
6   Salinidad             32 non-null     int64
7   Ciclos                32 non-null     int64
8   Producción_acumulada  32 non-null     float64
9   Gasto_combustible     32 non-null     float64
10  Gasto_grasas          32 non-null     float64
11  Gasto_mant            32 non-null     float64
12  N_intervenciones      32 non-null     int64
13  cambios_sla_en_5_años 32 non-null     object
14  Gasto_total           32 non-null     float64
15  SLA                   32 non-null     object
dtypes: float64(7), int64(5), object(4)
memory usage: 4.1+ KB
```

Figura 27. Tipo de data

Generar estadísticas descriptivas que analice series numéricas, objetos del dataframe, número de observación, , media de los valores, desviación estándar de las observaciones, máximo y mínimo valor en el objeto, así como los cuartiles que abarcan el 25%, 50% y 75% de las observaciones. Ver Figura 28

- Estadística descriptiva

```
In [5]: TESIS_UPSE.describe()

Out[5]:
```

	Profundidad	Reserva_fm	Gravedad_API	Temperatura	Salinidad	Ciclos	Producción_acumulada	Gasto_combustible	Gasto_grasas	Gasto_mant
count	32.000000	32.000000	32.000000	32.000000	32.000000	32.000000	32.000000	32.000000	32.000000	32.000000
mean	2955.125000	47.111875	39.090625	77.187500	21860.062500	7.812500	1813.566250	7964.874563	1798.229375	18768.443625
std	1333.391595	34.627473	1.784767	4.934654	6102.145508	8.471727	2010.450718	8310.587542	991.380816	14420.752656
min	806.000000	2.330000	35.000000	71.000000	11055.000000	1.000000	54.750000	379.620000	339.750000	3537.000000
25%	1653.750000	2.330000	38.250000	73.000000	16949.000000	2.000000	422.257500	1244.310000	934.200000	7568.652000
50%	3396.500000	73.530000	38.700000	77.000000	23952.000000	4.000000	1182.445000	5300.370000	1656.180000	15689.640000
75%	3845.500000	73.530000	39.850000	80.000000	26895.250000	9.000000	1943.625000	14767.200000	2616.075000	20330.100000
max	5423.000000	73.530000	43.500000	88.000000	32010.000000	30.000000	8395.000000	26151.528000	3789.900000	59343.000000

Figura 28. Estadística descriptiva del dataframe

Agrupar en una sola columna el SLA, aplicar una función para todas las filas con el mismo valor de esa columna y combinar los resultados en una estructura de datos, el comando count realiza un conteo de datos correspondiente a la variable. Ver Figura 29

- Agrupar dataframe

```
In [6]: TESIS_UPSE.groupby("SLA").SLA.count()

Out[6]:
SLA
BM    10
HL    14
SL    8
Name: SLA, dtype: int64
```

Figura 29. Agrupar dataframe

Contar las celdas que tengan número de entradas nulas para cada columna o fila de formación productora, número de intervenciones y cambios de SLA a partir del 2016-2020. Ver Figura 30

- Contar número de entradas nulas

```
In [7]: Contar_1= TESIS_UPSE['fm_productora'].value_counts()
Contar_2=TESIS_UPSE['N_intervenciones'].value_counts()
Contar_3= TESIS_UPSE['cambios_sla_en_5_años'].value_counts()
```

Figura 30. Contar celdas de entradas nulas

Mostrar el número máximo de filas y columnas perteneciente a formación productora, número de intervenciones y cambios de SLA a partir del 2016-2020. Ver Figura 31

```
In [8]: print("Cantidad de datos respecto a la formación productora:")
Contar_1
```

Cantidad de datos respecto a la formación productora:

```
Out[8]: AT    20
CPB     9
PB      2
ST      1
Name: fm_productora, dtype: int64
```

```
In [9]: print("Cantidad de datos respecto al número de intervenciones realizadas a los pozos:")
Contar_2
```

Cantidad de datos respecto al número de intervenciones realizadas a los pozos:

```
Out[9]: 0    21
1     2
6     2
3     2
9     1
33    1
15    1
31    1
11    1
Name: N_intervenciones, dtype: int64
```

```
In [10]: print("Cantidad de datos respecto al cambio de SLA en el periodo 2016-2020:")
Contar_3
```

Cantidad de datos respecto al cambio de SLA en el periodo 2016-2020:

```
Out[10]: NO    27
SI     5
Name: cambios_sla_en_5_años, dtype: int64
```

Figura 31. Mostrar el número de datos respecto a las variables analizadas

A continuación, gráfica de la producción acumulada en el período 2016-2020 de los pozos productivos de la sección 66 del campo GGV, la Figura 42 indica que BM es el SLA que mayor produce donde el pozo ANC0465 tiene una mayor producción respecto a los demás pozos productores y como sistema que menor producción tiene es HL. Ver Figura 32, Figura 33 y Anexo B y Anexo G.

- Gráfica Producción acumulada en el periodo 2016-2020 de los pozos productivos de la sección 66 del campo GVV

```
In [11]: EST_UPSE= TESIS_UPSE
fig = px.bar(EST_UPSE, x="Nombre_pozo", y="Producción_acumulada", color="SLA", barmode="group")
print("PRODUCCIÓN ACUMULADA EN EL PERIODO 2016-2020 DE LOS POZOS PRODUCTIVOS DE LA SECCION 66 DEL CAMPO GVV:")
fig.show()
```

Figura 32. Línea de código para graficar producción acumulada




Figura 33. Producción acumulada en el periodo 2016-2020

Por consiguiente, gráfica de Gastos totales generados en el periodo 2016-2020 de los pozos productivos de la sección 66 del campo GVV, al ser SW el mayor SLA que genera gastos en combustible, lubricantes y mantenimiento de equipos, la figura 44 indica que el pozo ANC0589 supera los \$70000 en comparación a los demás pozos productores durante este tiempo y como sistema que menor gastos genera es BM. Ver Figura 34 y Figura 35

- Gráfica Gastos totales generados en el periodo 2016-2020 de los pozos productivos de la sección 66 del campo GVV:

```
In [12]: EST_UPSE1 = TESIS_UPSE
fig = px.bar(EST_UPSE1, x="Nombre_pozo", y="Gasto_total", color="SLA", barmode="group")
print("GASTOS TOTALES GENERADOS EN EL PERIODO 2016-2020 DE LOS POZOS PRODUCTIVOS DE LA SECCION 66 DEL CAMPO GVV:")
fig.show()
```

Figura 34. Línea de código para graficar los gastos totales




Figura 35. Gastos totales generados en el periodo 2016-2020

De los barriles de petróleo producidos en el período 2016- 2020 de las formaciones productoras de la sección 66 del campo GVV, En la figura 46 se recalca la formación Atlanta por tener una producción acumulada que supera los 35000 bbls durante este tiempo, al ratificar que el SLA que predomina en la producción de petróleo es BM. Sin embargo, en el sistema de SW presenta una producción superior a los 10000 bbls y en el sistema de HL presenta una producción de aproximadamente 3000 bbls. Ver Figura 36, Figura 37, Anexo D, Anexo E y Anexo F.

• Gráfica Barriles de petróleo producidos en el período 2016-2020 de las formaciones productoras de la sección 66 del campo GVV

```
In [13]: EST_UPSE2 = TESIS_UPSE
fig = px.bar(EST_UPSE2, x="SLA", y="Producción_acumulada", color="fm_productora", barmode="group")
print("BARRILES DE PETROLEO PRODUCIDOS EN EL PERIODO 2016- 2020 DE LAS FORMACIONES PRODUCTORAS DE LA SECCION 66 DEL CAMPO GVV:")
fig.show()
```

Figura 36. Línea de código para graficar la producción total

BARRILES DE PETROLEO PRODUCIDOS EN EL PERIODO 2016- 2020 DE LAS FORMACIONES PRODUCTORAS DE LA SECCION 66 DEL CAMPO GVV:




Figura 37. Producción en el período 2016- 2020 de las formaciones

En la Figura 38 el pozo que mayor gravedad API presenta es ANC1678 con una gravedad superior a 43° al producir con SW, seguidamente los pozos con una gravedad API de 42.6° son ANCF02 y ANC0667 correspondiente al sistema de HL y referente a BM el pozo que presenta una gravedad API de 40° es ANC0446.

• Gráfica Pozos Productivos de la sección 66 del campo GVV con su respectiva Gravedad API

```
In [14]: EST_UPSE6 = TESIS_UPSE
fig = px.sunburst(EST_UPSE6, path=['SLA', 'Nombre_pozo'], values='Gravedad_API',
                 color='Gravedad_API')
fig.show()
```

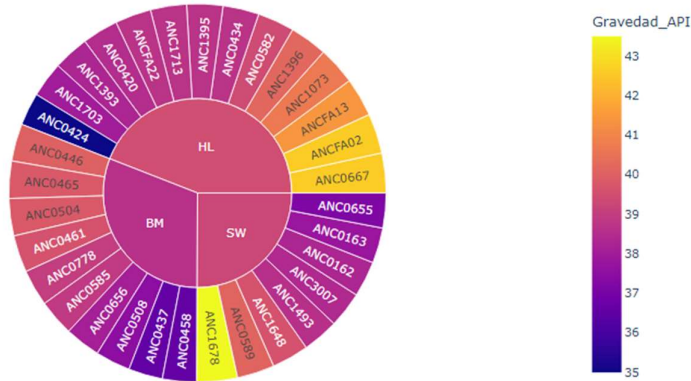


Figura 38. Pozos productores con su respectiva gravedad API

Identificar las variables más importantes previo al entrenamiento del algoritmo y poder considerar una relación directa entre las variables que se presentan en el dataframe, para ello utilizar coeficientes a través del método de Pearson, siendo 1 una correlación positiva completa, 0 sin correlación alguna y -1 una correlación negativa completa. Si la significancia es mayor a 0.05 la correlación entre las variables no existe y el valor obtenido pudo deberse al azar. Ver Figura 39

• Metodo Pearson

```
In [15]: TESIS_UPSE.corr()
Out[15]:
```

	Profundidad	Reserva_fm	Gravedad_API	Temperatura	Salinidad	Ciclos	Producción_acumulada	Gasto_combustible	Gasto_grasas
Profundidad	1.000000	0.905491	-0.217367	-0.004401	-0.126598	-0.238424	0.413828	-0.045383	0.223699
Reserva_fm	0.905491	1.000000	-0.320999	0.090260	-0.131716	-0.327580	0.445767	-0.105267	0.181871
Gravedad_API	-0.217367	-0.320999	1.000000	0.069065	0.163986	0.196798	0.055775	0.095723	0.062258
Temperatura	-0.004401	0.090260	0.069065	1.000000	0.288729	0.127416	-0.092842	-0.282360	-0.349534
Salinidad	-0.126598	-0.131716	0.163986	0.288729	1.000000	-0.053933	0.016783	0.234109	0.242272
Ciclos	-0.238424	-0.327580	0.196798	0.127416	-0.053933	1.000000	-0.501543	-0.202328	-0.501374
Producción_acumulada	0.413828	0.445767	0.055775	-0.092842	0.016783	-0.501543	1.000000	-0.091657	0.378509
Gasto_combustible	-0.045383	-0.105267	0.095723	-0.282360	0.234109	-0.202328	-0.091657	1.000000	0.815478
Gasto_grasas	0.223699	0.181871	0.062258	-0.349534	0.242272	-0.501374	0.378509	0.815478	1.000000
Gasto_mant	0.109874	0.030725	0.045484	-0.442930	-0.129801	-0.362202	0.326534	0.469003	0.574522
N_intervenciones	0.294522	0.273438	-0.070017	-0.312014	-0.385253	-0.297312	0.428736	0.170381	0.286470
Gasto_total	0.069708	-0.012265	0.073809	-0.442931	0.015313	-0.361045	0.210839	0.774718	0.783065

Figura 39. Método Pearson del dataframe

Con los valores de las correlaciones realizar un mapa de calor para identificar las variables altamente correlacionadas ya sea de manera positiva o negativa. En la interpretación del mapa los valores de las correlaciones están representadas con colores en el lado derecho,

siendo las más fuertes las de color violeta en representación de correlaciones negativas y las blancas son correlaciones positivas. Ver Figura 40

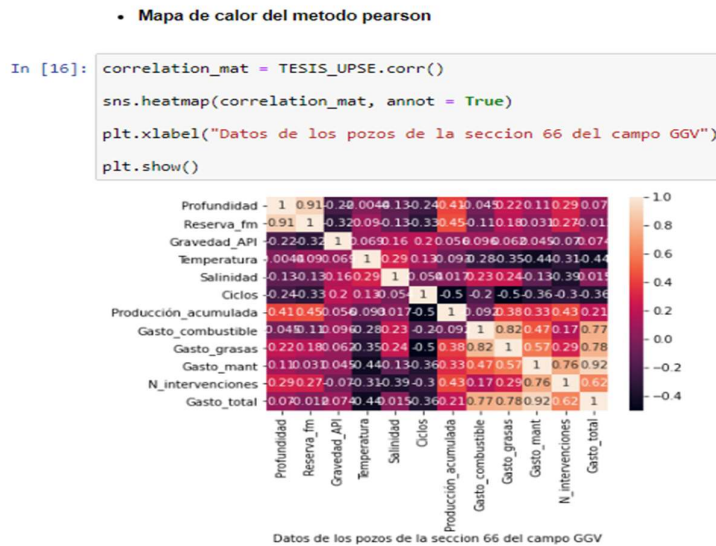


Figura 40. Mapa de calor del método Pearson

Una vez identificadas por el mapa de calor las variables altamente relacionadas, realizar un data cleaning en algunas columnas del dataframe: Formación productora, Nombre del Pozo, Gastos, Cambio de SLA en los últimos 5 años, Profundidad Verdadera, Salinidad y Temperatura. Ver Figura 41

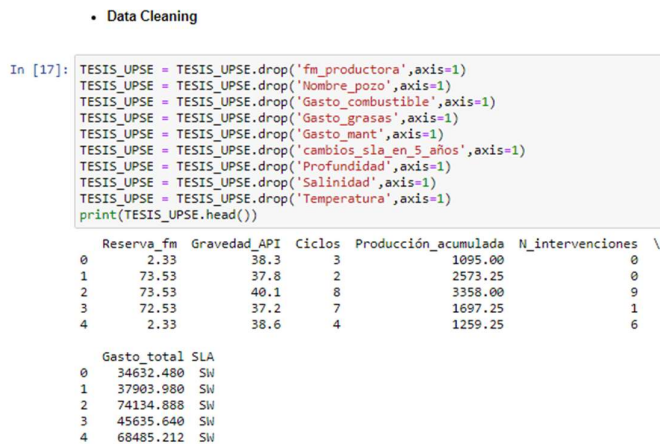


Figura 41. Data cleaning

Realizar una contabilización de variables una vez hecha la depuración del dataframe para obtener un Quality Assurance (QA) de los datos para asegurar la calidad y confiabilidad del algoritmo árbol de decisión. Ver Figura 42

- Quality Assurance

```
In [18]: TESIS_UPSE.count(0)/TESIS_UPSE.shape[0]*100
```

```
Out[18]: Reserva_fm          100.0
Gravedad_API          100.0
Ciclos                100.0
Producción_acumulada  100.0
N_intervenciones      100.0
Gasto_total           100.0
SLA                   100.0
dtype: float64
```

Figura 42. Aseguramiento de calidad

Con el preprocesamiento, data cleaning y QA completado, las variables determinadas por el algoritmo son: Reserva, Gravedad API, Ciclos, Producción acumulada, número de intervenciones, Gasto total y SLA. Ver Figura 43

- Variables seleccionadas por algoritmo

```
In [19]: predictors=TESIS_UPSE[['Reserva_fm','Gravedad_API', 'Ciclos','Producción_acumulada','N_intervenciones', 'Gasto_total' ]]
target=TESIS_UPSE.SLA
predictors
```

```
Out[19]:
```

	Reserva_fm	Gravedad_API	Ciclos	Producción_acumulada	N_intervenciones	Gasto_total
0	2.33	38.3	3	1095.00	0	34632.480
1	73.53	37.8	2	2573.25	0	37903.980
2	73.53	40.1	8	3358.00	9	74134.888
3	72.53	37.2	7	1697.25	1	45635.640
4	2.33	38.6	4	1259.25	6	68485.212
5	73.53	39.6	6	1679.00	0	38600.724
6	2.33	43.5	4	848.62	0	28281.228
7	73.53	38.4	3	1642.50	33	71441.760
8	73.53	38.5	12	415.18	0	21546.600
9	73.53	35.0	8	424.31	0	23226.600
10	73.53	38.7	6	428.87	0	22222.152
11	73.53	39.4	12	209.87	0	10909.200
12	73.53	42.6	25	416.10	0	21876.594
13	2.33	40.7	2	1245.56	0	39719.700
14	2.33	38.3	12	288.95	0	12454.284
15	2.33	38.7	30	109.50	0	5386.650
16	2.33	40.2	15	223.86	0	10839.276
17	2.33	38.0	6	577.91	0	23701.260

Figura 43. Predicción del algoritmo árbol de decisión

Imprimir el target del dataframe basado en el SLA. Ver Figura 44

```

In [20]: target
Out[20]: 0 SW
1 SW
2 SW
3 SW
4 SW
5 SW
6 SW
7 SW
8 HL
9 HL
10 HL
11 HL
12 HL
13 HL
14 HL
15 HL
16 HL
17 HL
18 HL
19 HL
20 HL
21 HL
22 BM
23 BM
24 BM
25 BM
26 BM
27 BM
28 BM
29 BM
30 BM
31 BM
Name: SLA, dtype: object

```

Figura 44. Target de SLA

Dar etiqueta a las variables determinadas por el algoritmo. Ver Figura 45

```

• Etiquetar variables

In [21]: predictors_labels=['Reserva_fm','Gravedad_API', 'Ciclos','Producción_acumulada','N_intervenciones', 'Gasto_total']
target_labels=['BM','HL','SW']
predictors_labels

Out[21]: ['Reserva_fm',
'Gravedad_API',
'Ciclos',
'Producción_acumulada',
'N_intervenciones',
'Gasto_total']

In [22]: target_labels
Out[22]: ['BM', 'HL', 'SW']

```

Figura 45. Etiquetar variables

Proceder a la fase del entrenamiento del algoritmo, por lo tanto, dividir el dataframe en dos porciones, el primer dataframe consiste en la mayor cantidad de datos que se utiliza para entrenar el modelo, para aquello ejecutar el modelo con la primera división del dataframe donde las predicciones se almacenan en una matriz. Ver Figura 46

```

ENTRENAMIENTO DEL ALGORITMO

In [23]: x_train,x_test,y_train,y_test=train_test_split(predictors,target,test_size=0.15,random_state=42)

```

Figura 46. Entrenamiento del algoritmo

Crear el algoritmo árbol de decisión, del cual necesitará como entrada dos matrices: una matriz X que contiene las muestras del entrenamiento, y una matriz Y que contiene las etiquetas de clase para las muestras del entrenamiento. Seguido de una profundidad del árbol de 5, lo que implica que cuanto más profundidad tenga el árbol más números de

nodos se grafican y la precisión de algoritmo tiende a un 100% lo cual se deduce como el porcentaje de valores clasificados correctamente al total de elementos. Ver Figura 47

```
• Creación del árbol de decisión

In [24]: arbol=DecisionTreeClassifier(max_depth=5)
         arbol.fit(x_train,y_train)
Out[24]: DecisionTreeClassifier(max_depth=5)
```

Figura 47. Creación del algoritmo árbol de decisión

Una vez entrenado el algoritmo con el primer dataframe que comprende un 85% del conjunto de datos, proceder con el segundo dataframe a evaluar y determinar si el modelo de árbol de decisión es oportuno. Ver Figura 48

```
• Predicción del árbol de decisión

In [25]: y_pred=arbol.predict(x_test)
         y_pred
Out[25]: array(['BM', 'HL', 'BM', 'HL', 'HL'], dtype=object)

In [26]: y_test
Out[26]: 29  BM
         15  HL
         24  BM
         17  HL
         8   HL
         Name: SLA, dtype: object
```

Figura 48. Predicción del algoritmo árbol de decisión

Implementar la función “metrics” que determina la exactitud que obtuvo el algoritmo al seleccionar el SLA óptimo para la sección 66 del campo GGV, cuyo mecanismo consiste en contar el número de predicciones a razón del número de muestras. Además de efectuar su propia puntuación en base a la evaluación de los datos de validación y target, con la finalidad de evaluar la calidad de predicción del algoritmo árbol de decisión. Para tal caso, la precisión del algoritmo indica que todas las muestras están bien clasificadas y su puntaje interno es altamente confiable. Ver Figura 49

```
• Precisión del algoritmo árbol de decisión

In [27]: print("precisión del arbol:", metrics.accuracy_score(y_test,y_pred))
         print("puntaje:", metrics.f1_score(y_test,y_pred,average="weighted"))
         precisión del arbol: 1.0
         puntaje: 1.0
```

Figura 49. Precisión del algoritmo árbol de decisión

Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. Uno de los beneficios de las

matrices de confusión es que facilitan ver si el sistema está confundiendo dos clases. Ver Figura 50

```
• Matriz de confusión

In [28]: cm=confusion_matrix(y_test,y_pred)
cm
Out[28]: array([[2, 0],
               [0, 3]], dtype=int64)
```

Figura 50. Matriz de confusión

Finalmente, graficar el algoritmo árbol de decisión. Ver Figura 51

```
• Gráfico del algoritmo árbol de decisión

In [29]: export_graphviz(arbol,
                        out_file='ARBOL_UPSE_RESULT.txt',
                        class_names=target_labels,
                        feature_names=predictors_labels,
                        filled=True)
Image("ARBOL_UPSE_RESULT.jpeg", width=1000, unconfined=True)
```

Figura 51. Árbol de decisión

3.3.1 Comprobación del sla seleccionado utilizando dos variables

Eliminar las etiquetas especificadas de filas o columnas correspondientes a: ciclos, número de intervenciones, Gravedad API, Reserva. Ver Figura 52

```
In [30]: TESIS_UPSE = TESIS_UPSE.drop('Ciclos',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('N_intervenciones',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Gravedad_API',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Reserva_fm',axis=1)
print(TESIS_UPSE.head())
```

	Producción_acumulada	Gasto_total	SLA
0	1095.00	34632.480	SW
1	2573.25	37903.980	SW
2	3358.00	74134.888	SW
3	1697.25	45635.640	SW
4	1259.25	68485.212	SW

Figura 52. Establecer las dos variables

Establecer solo las variables que el algoritmo analizará que es Producción acumulada y gasto total en base al SLA. Ver Figura 53

```
• Variables seleccionadas por algoritmo

In [31]: predictors1=TESIS_UPSE[['Producción_acumulada', 'Gasto_total' ]]
target1=TESIS_UPSE.SLA
```

Figura 53. Variables seleccionadas

Dar etiqueta a las variables determinadas por el algoritmo. Ver Figura 54

- Etiquetar variables

```
In [32]: predictors_labels1=['Producción_acumulada', 'Gasto_total']  
target_labels1=['BM','HL','SW']
```

Figura 54. Etiquetar las dos variables

Proceder a la fase del entrenamiento del algoritmo, por lo tanto, dividir el dataframe en dos porciones. El primer dataframe consiste en la mayor cantidad de datos, que se utiliza para entrenar el modelo, para aquello ejecutar el modelo con la primera división del dataframe donde las predicciones se almacenan en una matriz. Ver Figura 55

ENTRENAMIENTO DEL ALGORITMO CON DOS VARIABLES

```
In [33]: x_train,x_test,y_train,y_test=train_test_split(predictors1,target1,test_size=0.15,random_state=42)
```

Figura 55. Entrenamiento del algoritmo con dos variables

Crear el algoritmo árbol de decisión, del cual necesitará como entrada dos matrices: una matriz X que contiene las muestras del entrenamiento, y una matriz Y que contiene las etiquetas de clase para las muestras del entrenamiento. Seguido de una profundidad del árbol de 2. Ver Figura 56

- Creación del árbol de decisión con dos variables

```
In [34]: arbol1=DecisionTreeClassifier(max_depth=2)  
arbol1.fit(x_train,y_train)
```

```
Out[34]: DecisionTreeClassifier(max_depth=2)
```

Figura 56. Creación del árbol de decisión con dos variables

Una vez entrenado el algoritmo con el primer dataframe que comprende un 85% del conjunto de datos, proceder con el segundo dataframe a evaluar y determinar si el modelo de árbol de decisión es oportuno. Ver Figura 57

- Predicción del árbol de decisión con dos variables

```
In [35]: y_pred1=arbol1.predict(x_test)  
y_pred1
```

```
Out[35]: array(['BM', 'HL', 'BM', 'HL', 'HL'], dtype=object)
```

```
In [36]: y_test
```

```
Out[36]: 29    BM  
15    HL  
24    BM  
17    HL  
8     HL  
Name: SLA, dtype: object
```

Figura 57. Predicción del árbol de decisión con dos variables

Implementar la función “score” que determina la precisión del algoritmo en base a las dos variables analizadas, indicando que todas las muestras están bien clasificadas y

su puntaje interno es altamente confiable al seleccionar el SLA óptimo para la sección 66 del campo GGv. Ver Figura 58

```
• Precisión del algoritmo árbol de decisión con dos variables

In [37]: arbol1.score(x_train,y_train)

Out[37]: 0.8518518518518519
```

Figura 58. Precisión del algoritmo árbol de decisión con dos variables

Graficar el algoritmo árbol de decisión con dos variables; producción acumulada y gasto total. Ver Figura 59

```
• Gráfico del algoritmo árbol de decisión con dos variables

In [38]: export_graphviz(arbol1,
                        out_file='ARBOL_UPSE_COMPROBAR.txt',
                        class_names=target_labels1,
                        feature_names=predictors_labels1,
                        filled=True)
Image("ARBOL_UPSE_COMPROBAR.jpeg" , width=1000, unconfined=True)
```

Figura 59. Línea para generar el código del árbol de decisión con dos variables

CAPÍTULO IV: ANÁLISIS Y DISCUSIÓN DE RESULTADOS

4.1 MÉTODO DE SLA SELECCIONADO POR EL ALGORITMO DE ÁRBOL DE DECISIÓN

Con base a los resultados obtenidos por el algoritmo el SLA óptimo a implementar en el área de estudio es el BM como se muestra en la Figura 60; **Error! No se encuentra el origen de la referencia.** En cuanto al SLA por HL, la primera variable que el algoritmo considera para clasificar los datos es la producción acumulada en el periodo 2016-2020, al realizar la clasificación los 11 pozos analizados tuvieron una producción menor a 1252.40 barriles, este mismo caso ocurre para las variables gravedad API y ciclos en la cual todos los pozos tienen ciclos >1.5 y producen un crudo ≤ 43.05 . La siguiente variable considerada por el algoritmo es ciclo ≤ 3.5 en la cual 9 de los 11 pozos tienen ciclos mayores al establecido los dos restantes por ende tuvieron ciclos ≤ 3.5 a los cuales se los clasifica con la variable gasto total, ambos pozos tuvieron un gasto mayor a \$37176.09. Con esta clasificación se puede observar que el sistema HL no es factible a implementar en la sección 66 principalmente por su baja producción y sus altos costos de operación y mantenimiento.

En el caso del SLA por SW, de los 27 pozos que el algoritmo dispone para la prueba 8 de ellos operan con SW, la primera variable que el algoritmo considera es la producción acumulada en el periodo 2016-2020. De los ocho pozos analizados dos tuvieron una producción menor a 1252.40 barriles y seis tuvieron una producción mayor a 1252.40 barriles. La variable que considera el algoritmo para clasificar a los pozos que tuvieron una producción mayor 1252.40 barriles es gasto total ≤ 31654.59 , los seis pozos generan gastos por encima de ese valor. Con esta clasificación se obtiene que el sistema SW no es óptimo a implementar en la sección 66 a pesar de que el 75% de los pozos que operan con este SLA tienen una producción superior a los 1252.40 barriles, la principal

desventaja que presentan es que tienen gastos en operación y mantenimiento superiores a 31654.59 dólares por lo cual no es factible para la empresa.

Finalmente, para el SLA por BM el algoritmo dispone de ocho pozos, la primera variable que el algoritmo considera es la producción acumulada en el periodo 2016-2020, siete de ocho pozos analizados tuvieron una producción mayor a 1252.40 barriles, continuando con la clasificación la siguiente variable analizada es gasto total del cual seis de los siete pozos tuvieron un gasto menor a 31654.59 dólares. Con esta clasificación el algoritmo considera que el SLA óptimo a implementar en la sección 66 es BM debido a que es el sistema con el cual se obtiene una mayor producción de petróleo y a su vez es el SLA que menos gastos genera.

Para lograr estos resultados se le designó al algoritmo árbol de decisión el 15% de los datos para el entrenamiento, el porcentaje restante (85%) automáticamente los utiliza para realizar la prueba, es decir de la información de los 32 pozos que constan en la base de datos: 5 fueron usados para entrenamiento y 27 para la prueba, escogió aleatoriamente 8 pozos que operan con BM, 11 con HL y 8 con SW.




Figura 60. Árbol de decisión

Para demostrar que el BM es el SLA óptimo a implementar, a continuación, se analiza los nodos del árbol obtenido:

Aquellos pozos en los que se cumple la condición: producción acumulada ≤ 1252.405 barriles de petróleo producidos en el periodo 2016-2020 como muestra la Figura 61, tienden a ser clasificados hacia la izquierda (true) caso contrario los que no cumplen con dicha condición es decir que tengan una producción acumulada > 1252.405 barriles tienden a seguir hacia la derecha (false), el coeficiente de gini indica el grado de impureza que tiene cada nodo al momento de realizar la clasificación de datos, la impureza se refiere a cómo de mezcladas están las clases en cada nodo a mayor coeficiente de gini menor será el grado de pureza, un gini de 0.658 indica un alto grado de impureza puesto

que en el nodo existen tres clases (BM, HL, SW). Cabe recalcar que los 11 pozos operados con SLA por HL que el algoritmo seleccionó, obtuvieron una producción acumulada ≤ 1252.405 barriles mientras que 7 de 8 pozos que operan con SLA por BM tuvieron una producción acumulada > 1252.405

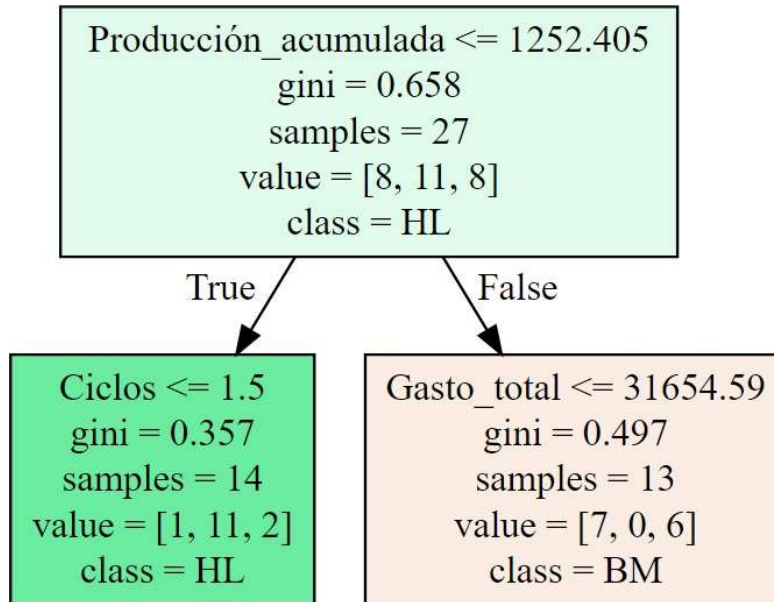


Figura 61. Nodos de producción acumulada, ciclos y gasto total

Para el caso producción acumulada ≤ 1252.405 barriles (True), se puede observar en la Figura 61 que 14 de 27 pozos cumplen con esta condición, la siguiente variable que el algoritmo utiliza para realizar la clasificación de datos es “ciclos”, la razón por la que el algoritmo escogió esta variable se debe al grado de pureza, el gini es de 0.357, al igual que en el nodo anterior se dispone de 3 clases (BM, HL, SW), se podría pensar que al tener la misma cantidad de clases el gini debería ser igual (0.658), sin embargo para la variable ciclos el coeficiente de gini ha disminuido porque en dos clases se cuenta con menor cantidad de pozos; 1 por BM y 2 por SW. Los pozos que tienden a cumplir con la condición $\text{ciclos} \leq 1.5$ siguen hacia la izquierda y aquellos que tengan un ciclo > 1.5 siguen hacia la derecha.

Se puede observar en la Figura 62, que de 14 pozos uno de ellos (operado con BM) cumple con la condición $\text{ciclo} \leq 1.5$, el coeficiente de gini es 0 debido a que no existe otra clase aparte de BM, es decir que no existe impureza en el nodo, con esto el algoritmo ha clasificado el primer pozo de 27 que fueron tomados para realizar la prueba.

Los pozos que no cumplen la condición $\text{ciclo} \leq 1.5$ tienden hacia la derecha, clasificándolos en 2 clases; 11 pozos con SLA por HL y 2 por SW, el algoritmo considera otra variable para continuar con la clasificación de datos, siendo la condición $\text{gravedad}_{\text{api}} \leq 43.05$,

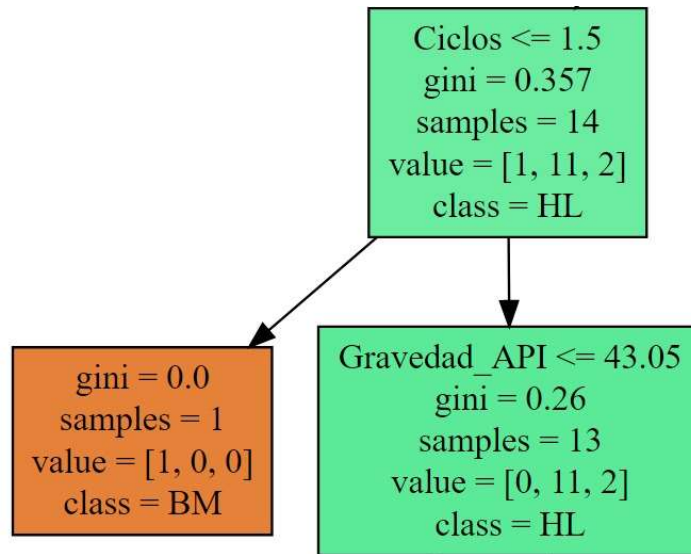


Figura 62. Nodos de ciclos y gravedad API

La siguiente variable que el algoritmo analiza es gravedad api, como muestra la Figura 63 aquellos pozos que cumplan con la condición $\text{gravedad}_{\text{api}} \leq 43.05$ tienden a la izquierda y aquellos pozos que cumplan con $\text{gravedad}_{\text{api}} > 43.05$ tienden hacia la derecha, En este nodo el coeficiente gini es de 0.26 ya que se dispone de 2 clases por lo tanto el grado de impureza es menor. De los 13 pozos, uno de ellos operado con SLA por SW produce un crudo con mayor gravedad a la establecida, el gini en este nodo es 0 porque no se encuentra otra clase con la cual realizar una clasificación, mientras que 12 pozos (11 operan con HL y 1 con SW) producen un crudo ≤ 43.05 .

El algoritmo analiza nuevamente la variable ciclos debido a que el gini generado es menor al que obtendría con otra variable como por ejemplo gastos, con lo cual puede clasificar los datos con un menor grado de impureza.

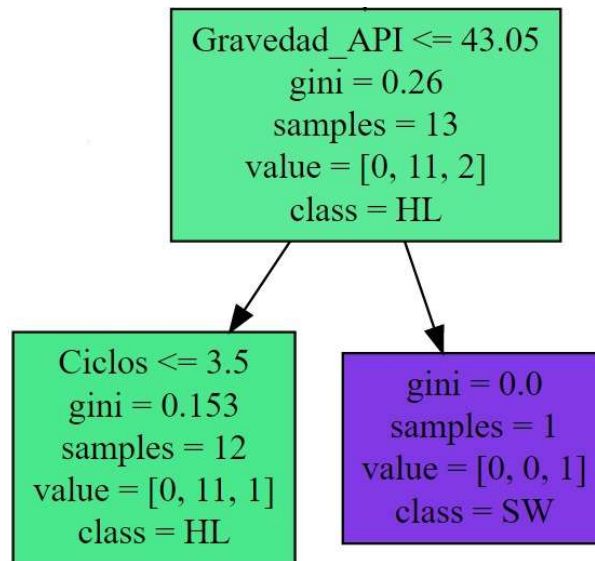


Figura 63. Nodos de gravedad API y ciclos

Los pozos que cumplen con la condición $\text{ciclos} \leq 3.5$, tienden a seguir hacia la izquierda y aquellos que tienen $\text{ciclos} > 3.5$ tienden hacia la derecha como se observa en la Figura 64. En este nodo el gini es de 0.153 lo cual muestra un menor grado de impureza, debido a que se tiene un pozo operado con SLA por SW y 11 con HL, cabe recalcar que el gini es 0 cuando solo quedan datos de una clase, tal caso ocurre en el nodo que se genera cuando los pozos tienen $\text{ciclos} > 3.5$

Para el caso de los pozos que cumplen la condición $\text{ciclos} \leq 3.5$, se analiza una nueva variable la cual es gasto total.

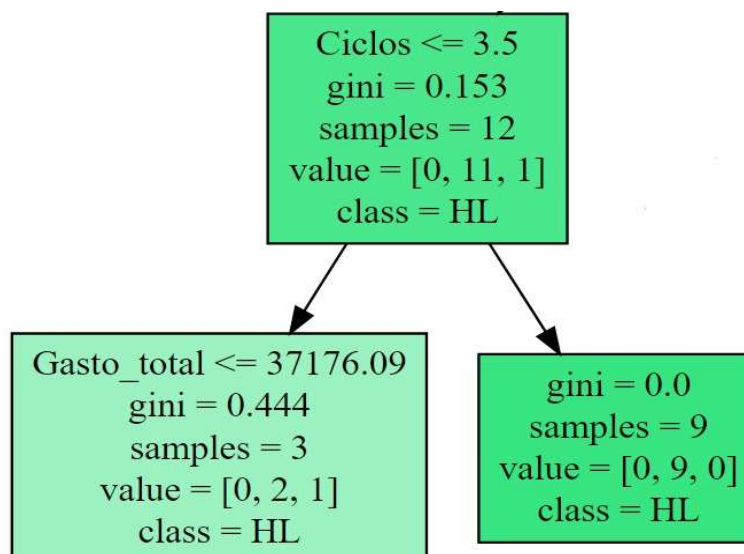


Figura 64. Nodos de ciclos y gasto total

La siguiente variable por considerar es gasto total como se muestra en la Figura 65, en la cual se tienen tres pozos, aquellos pozos que cumplen con la condición $\text{gasto total} \leq 37176.09$ dólares tienden hacia la izquierda y aquellos pozos que cumplen con $\text{gasto total} > 37176.09$ dólares tienden hacia la derecha, dos de tres pozos tienen un gasto mayor al especificado, ambos pozos operan con el sistema HL, mientras que el pozo que tiene un gasto menor opera con SLA por SW. En ambos nodos el gini es cero debido a que no existe otra clase con la cual se pueda realizar una siguiente clasificación.




Figura 65. Nodo de gasto total

Los pozos que tienen una producción acumulada > 1252.405 barriles tienden hacia la derecha como se muestra en la Figura 61, en este nodo se puede observar que 13 pozos cumplieron con esta característica, de los cuales 7 operan con SLA por BM y 6 operan con el SLA por SW [7,0,6].

En la Figura 66 se observa que el algoritmo utiliza la condición $\text{gasto total} \leq 31654.59$ para clasificar los datos, aquellos pozos que cumplen dicha condición tienden hacia la izquierda y los que generan un gasto superior a ese valor tienden hacia la derecha. De los siete pozos que operan con BM, seis tuvieron un gasto total ≤ 31654.59 en este nodo el gini es de cero debido a que es la única clase presente. Los Pozos que generan un gasto mayor al de la condición son; seis por SW y uno opera con SLA por BM




Figura 66. Nodos de gasto total y ciclos

En la Figura 67 el algoritmo considera la variable ciclos para realizar la siguiente clasificación, para este caso separa los pozos que tienen ciclos ≤ 1.5 de aquellos que tienen ciclos mayores. Se dispone de siete pozos, al realizar la clasificación seis pozos que operan con SLA por SW tiene ciclos > 1.5 , mientras que un pozo que opera con BM tiene ciclo ≤ 1.5 .




Figura 67. Nodo de ciclos

Para comprobar que el algoritmo utilizó los 27 datos de prueba que se le asignó se suman el valor de las clases que hay en cada uno de los nodos en el que el gini es cero, observar Figura 60 .

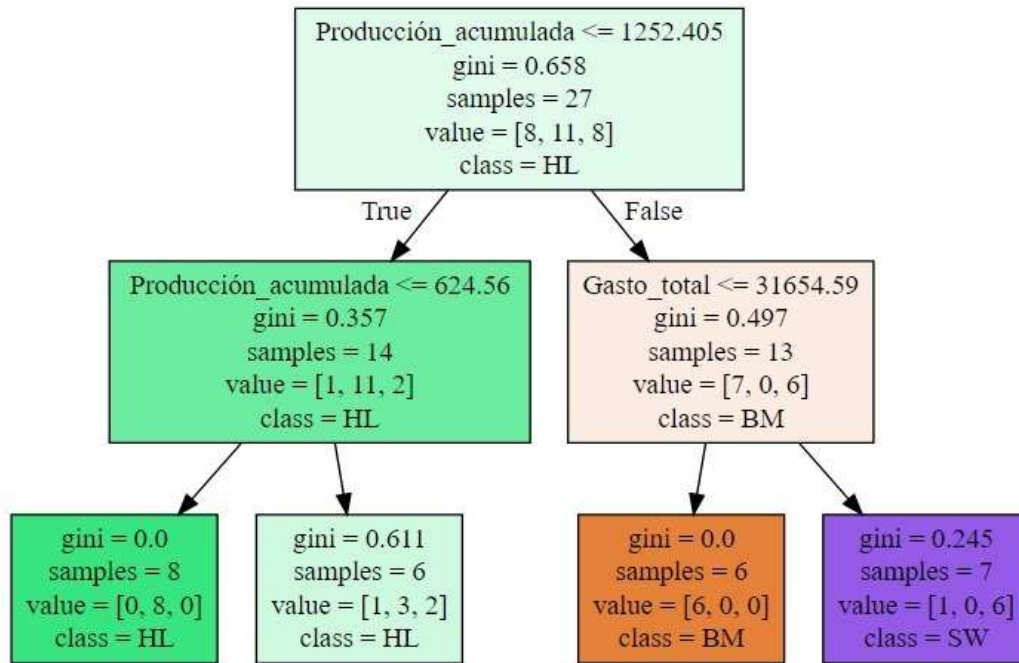


Figura 68. Árbol de decisión con dos variables

En la Figura 68 se observa la clasificación de datos del algoritmo árbol de decisión utilizando dos variables; producción acumulada y gasto total, da como resultado que el SLA óptimo a implementar en toda la sección 66 es BM. Los pozos que operan con BM obtuvieron una mejor tasa de producción en el periodo 2016-2020 en comparación a los pozos que producen con otros SLA, y a su vez generaron menor gasto de operación y mantenimiento debido a que las intervenciones que se realizan en los pozos son de bajo costo, además se economiza dinero en combustible, grasas, lubricantes y repuestos.

4.2 ANÁLISIS ECONÓMICO

El análisis económico proyectado para los 22 pozos que producen con otro sistema diferente al de BM; 14 con HL y 8 con SW tiene como objetivo principal determinar la viabilidad o no del proyecto, generando cuatro flujos de cajas para su respectivo análisis. Para lograr el objetivo se requiere plantear dos escenarios para el SLA por HL y dos por SW: el primero tanto para HL como SW muestra el desarrollo económico de la compañía

proyectado a 36 meses sin realizar ninguna inversión. El segundo, muestra el desarrollo económico de la compañía en la que requiere una inversión para cambiar de SLA.

4.2.1 Desarrollo del análisis económico

- a) **Pronóstico de Ingresos.** Para calcular el pronóstico de ingresos tomar en cuenta la producción mensual de los SLA por SW y HL a razón de la tasa de declinación en la sección 66 de un 0,25% mensual y con un precio actual del barril de petróleo de \$70/bls como se muestra en la ecuación (6). Como se muestra en la Tabla C 4 y Anexo C

$$\text{Ingresos} = \text{Producción mensual} * \text{Precio Barril de petróleo} \quad (6)$$

- b) **Inversión.** Llevar a cabo el cambio del SLA de los 8 pozos que operan con SW a BM requiere de una inversión de \$141699.65 siendo de ese modo un presupuesto de \$17712.45 por pozo, para realizar el cambio del SLA de los 14 pozos que operan con HL a BM requiere una inversión de \$241597.77 de los cuales \$17526.98 corresponde al presupuesto para cada pozo. La inversión total del proyecto es \$383296,87. Los valores de inversión considerados para el cambio de SW a BM son presentados en la siguiente tabla:

Tabla 25. Inversión requerida para el cambio del SLA SW a BM

	DESCRIPCIÓN	UNIDAD	CANTIDAD	PRECIO UNITARIO (\$)	PRECIO TOTAL (\$)
	Balancín portátil	und	2	21000	42000
EQUIPO DE SUPERFICIE	Carreta de almacenamiento	und	2	10000	20000
	Puente de producción	und	8	698,48	5587,84
	Stuffing box	und	8	600	4800
	Grampa	und	8	500	4000
	Asiento 2 3/8", 8RD, EUE	und	8	2034,4	16275,2
EQUIPO DE FONDO	Tubería perforada + tapón 2 3/8"	und	8	121,67	973,36
	Bomba de subsuelo	und	8	2025,2	16201,6
	Varillas de subsuelo 5/8"x 25" A/C	ft	2230,02	3	6690,06
	Varillas de subsuelo 3/4"x 25" A/C	ft	7095,32	3,2	22705,024
	Neplo de varillas; 3/4"x10" Lng.	und	8	115,72	925,76
	Varillón pulido 1 1/4"x 3/4x	und	8	192,6	1540,8
COSTO DE INVERSIÓN					\$141699,65

Los valores de inversión considerados para el cambio de HL a BM son presentados en la siguiente tabla:

Tabla 26. Inversión requerida para el cambio del SLA HL a BM

	DESCRIPCIÓN	UNIDAD	CANTIDAD	PRECIO UNITARIO (\$)	PRECIO TOTAL (\$)
	Balancín portátil	und	3	21000	63000
EQUIPO DE SUPERFICIE	Puente de producción	und	14	698,48	9778,72
	Stuffing box	und	14	600	8400
	Grampa	und	14	500	7000
	Carreta de almacenamiento	und	3	10000	30000
	Asiento 2 3/8", 8RD, EUE	und	14	2034,4	28481,6
	Tubería perforada + tapón 2 3/8"	und	14	121,67	1703,38
	Varillas de subsuelo 3/4"x 25" A/C	ft	5398,70	3,2	17275,84
EQUIPO DE FONDO	Varillas de subsuelo 5/8"x 25" A/C	ft	14429,64	3	43288,92
	Neplo de varillas; 3/4"x10" Lng.	und	14	115,72	1620,08
	Bomba de subsuelo	und	14	2025,2	28352,8
	Varillón pulido	und	14	192,6	2696,4
	COSTO DE INVERSIÓN				241597,72

c) **Distribución del proyecto en Periodos.** Para efectuar el análisis del proyecto se procede a dividir en periodos con una extensión de 36 meses (3 años) que requiere la Compañía para optimizar el SLA en la sección 66 del Campo GGV a partir del cuarto mes se inicia el cambio de SLA actual por el sistema de BM siendo este el seleccionado por el algoritmo árbol de decisión. Una vez dividido en periodos se emplea el flujo de caja.

d) **Flujo de caja sin proyecto para el SLA SW.** La Tabla 27 representa los ingresos netos sin considerar la implementación del proyecto programado para 36 periodos equivalente a 36 meses para el SLA por el método de SW. Por tanto, la ecuación (7) del flujo de caja tiene dos componentes:

$$\text{Flujo de caja sin proyecto} = \text{Ingresos} - \text{Gastos por SW} \quad (7)$$

Al flujo de caja sin proyecto se aplicó actualización que consiste en determinar los flujos netos futuros de efectivo descontando la tasa de interés del 1,25% mensual (15% anual) fijada por la compañía Pacifpetrol. De modo que los ingresos actualizados son \$561828,92 y los egresos actualizados de \$ 236472,91

Finalmente, el flujo de caja sin implementar el proyecto obtuvo una ganancia de \$329474,44 y un VAN de \$ 265537,74 con una TIR es de 6% siendo este valor superior a la tasa de descuento mensual lo que indica que para los ocho pozos que operan con el SLA SW en la sección 66 del campo GGV la inversión puede ser recuperada.

Tabla 27, Flujo de caja sin proyecto con el SLA SW

PERÍODO (MES)	PRODUCCIÓN DIARIA BPD (declinación 0,25%)	PRODUCCIÓN MENSUAL BPD (declinación 0,25%)	INGRESOS (\$)	INGRESOS ACTUALIZADOS (\$)	GASTOS SWAB (\$)	GASTOS DE BOMBEO MECÁNICO (\$)	GASTOS DE OPERACIÓN (\$)	INVERSIÓN (\$)	EGRESOS (\$)	EGRESOS ACTUALIZADOS (\$)	FLUJO DE CAJA (\$)	FLUJO DE CAJA ACUMULADO (\$)	VALOR ACTUAL NETO (\$)
1	7,86	235,80	16506,00	16299,68	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9854,16	9854,16	9732,50
2	7,84	235,21	16464,74	16258,93	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9812,90	19667,06	9572,10
3	7,82	234,62	16423,57	16218,28	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9771,73	29438,79	9414,27
4	7,80	234,04	16382,51	16177,73	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9730,67	39169,46	9258,97
5	7,78	233,45	16341,56	16137,29	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9689,72	48859,18	9106,17
6	7,76	232,87	16300,70	16096,95	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9648,86	58508,04	8955,83
7	7,74	232,29	16259,95	16056,70	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9608,11	68116,16	8807,91
8	7,72	231,70	16219,30	16016,56	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9567,46	77683,62	8662,37
9	7,70	231,13	16178,75	15976,52	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9526,91	87210,53	8519,16
10	7,68	230,55	16138,31	15936,58	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9486,47	96697,00	8378,27
11	7,67	229,97	16097,96	15896,74	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9446,12	106143,12	8239,64
12	7,65	229,40	16057,72	15857,00	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9405,88	115549,00	8103,24
13	7,63	228,82	16017,57	15817,35	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9365,73	124914,73	7969,05
14	7,61	228,25	15977,53	15777,81	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9325,69	134240,42	7837,01
15	7,59	227,68	15937,58	15738,36	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9285,74	143526,16	7707,10
16	7,57	227,11	15897,74	15699,02	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9245,90	152772,06	7579,29
17	7,55	226,54	15858,00	15659,77	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9206,16	161978,22	7453,54
18	7,53	225,98	15818,35	15620,62	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9166,51	171144,73	7329,82
19	7,51	225,41	15778,81	15581,57	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9126,97	180271,70	7208,10

20	7,49	224,85	15739,36	15542,62	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9087,52	189359,22	7088,34		
21	7,48	224,29	15700,01	15503,76	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9048,17	198407,39	6970,52		
22	7,46	223,73	15660,76	15465,00	-6651,84	0	-6651,84	0	-6651,84	-6568,692	9008,92	207416,31	6854,60		
23	7,44	223,17	15621,61	15426,34	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8969,77	216386,07	6740,55		
24	7,42	222,61	15582,55	15387,77	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8930,71	225316,79	6628,35		
25	7,40	222,05	15543,60	15349,30	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8891,76	234208,55	6517,96		
26	7,38	221,50	15504,74	15310,93	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8852,90	243061,44	6409,36		
27	7,36	220,94	15465,98	15272,65	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8814,14	251875,58	6302,52		
28	7,35	220,39	15427,31	15234,47	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8775,47	260651,05	6197,40		
29	7,33	219,84	15388,74	15196,38	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8736,90	269387,96	6093,99		
30	7,31	219,29	15350,27	15158,39	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8698,43	278086,39	5992,25		
31	7,29	218,74	15311,90	15120,50	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8660,06	286746,44	5892,16		
32	7,27	218,19	15273,62	15082,70	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8621,78	295368,22	5793,70		
33	7,25	217,65	15235,43	15044,99	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8583,59	303951,81	5696,83		
34	7,24	217,10	15197,34	15007,38	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8545,50	312497,32	5601,53		
35	7,22	216,56	15159,35	14969,86	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8507,51	321004,83	5507,78		
36	7,20	216,02	15121,45	14932,43	-6651,84	0	-6651,84	0	-6651,84	-6568,692	8469,61	329474,44	5415,55		
								Total inversión=	0					VAN =	4521554
														TIR=	6%

e) *Flujo de caja con proyecto.* La Tabla 28 representa los ingresos netos al considerar la implementación del SLA de BM por el método de SW programado para 36 periodos equivalente a 36 meses. Por tanto, la ecuación (8) del flujo de caja tiene cuatro componentes:

Flujo de caja con proyecto

$$= \text{Ingresos} - \text{Gastos por SW} - \text{Gastos por BM} - \text{Inversión} \quad (8)$$

El flujo de caja con la implementación del proyecto en los 36 periodos muestra que:

La columna de ingresos en el primer trimestre es baja ya que produce por el método de SW, a partir del cuarto periodo los ingresos aumentan ya que la producción varía por la implementación del método de BM.

La columna de Gastos por SW a partir del primer hasta el séptimo periodo se reduce de \$6651,84 a 0, debido a que en ese periodo se cambia el método de SW en el que operan los ocho pozos por el método de BM.

La columna de inversión a partir del cuarto hasta el séptimo periodo la compañía invierte \$141699,65 para crear la infraestructura que requerirá el proyecto, en el octavo periodo la inversión se ha recuperado.

La columna de gastos de operación por BM a partir del cuarto periodo que inicia la ejecución del proyecto se incrementa mensualmente de \$204,12 que es el costo de operación por cada dos pozos hasta llegar a \$816,48 siendo el costo de operación por los ocho pozos de BM.

Al flujo de caja con proyecto se aplicó actualización que consiste en determinar los flujos netos futuros de efectivo descontando la tasa de interés del 1,25% mensual (15% anual) fijada por la compañía Pacifpetrol. De modo que, los ingresos actualizados son \$941878,73 y los egresos actualizados de \$54959,74

Finalmente, el flujo de caja con la implementación del proyecto obtuvo una ganancia de \$898148,85 y un VAN de \$ 567377,51 con una tasa de interés del 1,25% mensual en un periodo de 36 meses para los ocho pozos que cambiaron del método de extracción de SW a BM en la sección 66 del campo GGV. Lo que indica que todos los flujos de caja que se desarrollaran en el futuro al aplicar el proyecto equivalen a que la compañía tenga \$ 567377,51 en el tiempo cero.

Por ende, queda demostrado que con la implementación del método de BM la producción aumenta en un 70% con respecto a la producción que se presentaba con el método de SW, además que el VAN de \$ 567377,51 es superior al VAN de \$265537,74 obtenido sin implementar el proyecto. El TIR es de 14% obtenido a partir de los valores del flujo de caja para el periodo establecido, siendo este valor superior a la tasa de descuento mensual y superior a la TIR que se obtiene sin implementar el proyecto, esto indica que la inversión puede ser recuperada, concluyendo que resulta factible el cambio de SLA.

Tabla 28. Flujo de caja con proyecto para el SLA SW

PERÍODO (MES)	PRODUCCIÓN DIARIA BPD (declinación 0,25%)	PRODUCCIÓN MENSUAL BPD (declinación 0,25%)	INGRESOS (\$)	INGRESOS ACTUALIZADOS (\$)	GASTOS SWAB (\$)	GASTOS DE BOMBEO MECÁNICO (\$)	GASTOS DE OPERACIÓN (\$)	INVERSIÓN (\$)	EGRESOS (\$)	EGRESOS ACTUALIZADOS (\$)	FLUJO DE CAJA (\$)	FLUJO DE CAJA ACUMULADO (\$)	VALOR ACTUAL NETO (\$)
1	7,86	235,80	16506,00	16299,68	-6651,84	0,00	-6651,84	0,00	-6651,84	-6568,69	9854,16	9854,16	9732,50
2	7,84	235,21	16464,74	16258,93	-6651,84	0,00	-6651,84	0,00	-6651,84	-6568,69	9812,90	19667,06	9572,10
3	7,82	234,62	16423,57	16218,28	-6651,84	0,00	-6651,84	0,00	-6651,84	-6568,69	9771,73	29438,79	9414,27
4	9,36	280,70	19648,76	19403,15	-4988,88	-204,12	-5193,00	-35424,90	-5193,00	-5128,09	14455,76	43894,54	13755,00
5	11,45	343,54	24047,73	23747,13	-3325,92	-408,24	-3734,16	-35424,90	-3734,16	-3687,48	20313,57	64208,11	19090,23
6	12,68	380,35	26624,27	26291,47	-1662,96	-612,36	-2275,32	-35424,90	-2275,32	-2246,88	24348,95	88557,07	22600,09
7	13,73	411,77	28823,76	28463,46	0,00	-816,48	-816,48	-35424,90	-816,48	-806,27	28007,28	116564,35	25674,72
8	13,69	410,74	28751,70	28392,30	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27935,22	144499,57	25292,51
9	13,66	409,71	28679,82	28321,32	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27863,34	172362,91	24915,98
10	13,62	408,69	28608,12	28250,52	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27791,64	200154,55	24545,05
11	13,59	407,67	28536,60	28179,89	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27720,12	227874,67	24179,64
12	13,55	406,65	28465,26	28109,44	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27648,78	255523,45	23819,66
13	13,52	405,63	28394,10	28039,17	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27577,62	283101,07	23465,04
14	13,49	404,62	28323,11	27969,07	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27506,63	310607,70	23115,70
15	13,45	403,60	28252,30	27899,15	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27435,82	338043,52	22771,55
16	13,42	402,60	28181,67	27829,40	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27365,19	365408,72	22432,52
17	13,39	401,59	28111,22	27759,83	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27294,74	392703,46	22098,53
18	13,35	400,58	28040,94	27690,43	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27224,46	419927,92	21769,51

Tabla 25. (Continuación)

19	13,32	399,58	27970,84	27621,20	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27154,36	447082,27	21445,39	
20	13,29	398,58	27900,91	27552,15	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27084,43	474166,71	21126,09	
21	13,25	397,59	27831,16	27483,27	0,00	-816,48	-816,48	0,00	-816,48	-806,27	27014,68	501181,38	20811,54	
22	13,22	396,59	27761,58	27414,56	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26945,10	528126,49	20501,66	
23	13,19	395,60	27692,18	27346,03	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26875,70	555002,18	20196,40	
24	13,15	394,61	27622,95	27277,66	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26806,47	581808,65	19895,68	
25	13,12	393,63	27553,89	27209,47	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26737,41	608546,06	19599,43	
26	13,09	392,64	27485,00	27141,44	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26668,52	635214,58	19307,59	
27	13,06	391,66	27416,29	27073,59	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26599,81	661814,40	19020,10	
28	13,02	390,68	27347,75	27005,90	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26531,27	688345,67	18736,88	
29	12,99	389,71	27279,38	26938,39	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26462,90	714808,57	18457,87	
30	12,96	388,73	27211,18	26871,04	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26394,70	741203,27	18183,01	
31	12,93	387,76	27143,16	26803,87	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26326,68	767529,95	17912,25	
32	12,89	386,79	27075,30	26736,86	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26258,82	793788,77	17645,51	
33	12,86	385,82	27007,61	26670,01	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26191,13	819979,90	17382,74	
34	12,83	384,86	26940,09	26603,34	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26123,61	846103,51	17123,88	
35	12,80	383,90	26872,74	26536,83	0,00	-816,48	-816,48	0,00	-816,48	-806,27	26056,26	872159,77	16868,87	
36	12,76	382,94	26805,56	26470,49	0	-816,48	-816,48	0	-816,48	-806,274	25989,08	898148,85	16617,65	
							Total inversión	-141699,60					VAN =	567377,51
													TIR	14%

f) **Análisis comparativo de flujos de caja.** Realizar un análisis comparativo de los flujos de caja del proyecto permite interpretar la diferencia entre la situación actual y posterior si se implementa el proyecto. En la Figura 69 muestra el comportamiento actual si no se implementa el método de BM por el método de SW.




Figura 69. Gráfico de flujo de caja sin implementar el proyecto

Sin embargo, al implementar el proyecto el resultado que se obtiene se muestra en la Figura 70




Figura 70. Gráfico de flujo de caja con la implementación proyecto

Finalmente, en la Figura 71 se observa el resultado que tiene la implementación del BM sobre el método de extracción actual que es el SW de los ocho pozos de la sección 66 del Campo GGV. La tendencia de la línea amarilla indica que los ingresos por producción al implementar el método de BM son superiores a los del método de SW, es decir, que si se producía con 235 bls por mes con ingreso de \$16506, en la implementación del proyecto se tendría 411,77 bls por mes con ingreso de \$28463,46. La tendencia de la línea celeste indica que los gastos operativos por BM son inferiores a los del método de SW y solo en el primer trimestre se tienen los mismos gastos debido a que a partir del cuarto periodo se inicia la implementación del proyecto. La tendencia de la línea verde indica el comportamiento del flujo de caja con la implementación del método de BM donde podemos observar la rentabilidad económica comparada con el flujo de caja sin implementar el proyecto.

En conclusión, implementar el método de BM en los ocho pozos que operan por el método de SW es factible y los resultados obtenidos indican un aumento en la producción, ganancias y el VAN.




Figura 71. Gráfico comparativo de flujos de caja

g) Flujo de caja sin proyecto para el SLA HL. La Tabla 29 representa los ingresos netos sin considerar la implementación del proyecto programado para 36 periodos equivalente a 36 meses para el SLA por el método de HL, por tanto, la ecuación (9) del flujo de caja tiene dos componentes:

$$\text{Flujo de caja sin proyecto} = \text{Ingresos} - \text{Gastos por HL} \quad (9)$$

Al flujo de caja sin proyecto se aplicó actualización que consiste en determinar los flujos netos futuros de efectivo descontando la tasa de interés del 1,25% mensual (15% anual) fijada por la compañía Pacifpetrol. De modo que los ingresos actualizados son \$268048,15 y los egresos actualizados de \$ 185711,78.

Finalmente, el flujo de caja sin implementar el proyecto obtuvo una ganancia de \$83378,60 y un VAN de \$ 67540,22 con una TIR es de 2% siendo este valor superior a la tasa de descuento mensual (1,25%) lo que indica que para los 14 pozos que operan con el SLA HL en la sección 66 del campo GGV la inversión puede ser recuperada.

Tabla 29. Flujo de caja sin proyecto para el SLA HL

PERÍODO (MES)	PRODUCCIÓN DIARIA BPD (declinación 0,25%)	PRODUCCIÓN MENSUAL BPD (declinación 0,25%)	INGRESOS (\$)	INGRESOS ACTUALIZADOS (\$)	GASTOS HERRAMIENTA LOCAL (\$)	GASTOS DE BOMBEO MECÁNICO (\$)	GASTOS DE OPERACIÓN (\$)	INVERSIÓN (\$)	EGRESOS (\$)	EGRESOS ACTUALIZADOS (\$)	FLUJO DE CAJA (\$)	FLUJO DE CAJA ACUMULADO (\$)	VALOR ACTUAL NETO (\$)
1	3,75	112,5	7875,00	7776,56	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2651,04	2651,04	2618,31
2	3,74	112,2	7855,31	7757,12	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2631,35	5282,39	2566,78
3	3,73	111,9	7835,67	7737,73	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2611,71	7894,11	2516,17
4	3,72	111,7	7816,09	7718,38	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2592,13	10486,23	2466,47
5	3,71	111,4	7796,54	7699,09	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2572,58	13058,82	2417,66
6	3,70	111,1	7777,05	7679,84	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2553,09	15611,91	2369,72
7	3,69	110,8	7757,61	7660,64	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2533,65	18145,56	2322,64
8	3,68	110,5	7738,22	7641,49	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2514,26	20659,82	2276,40
9	3,68	110,3	7718,87	7622,39	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2494,91	23154,73	2231,00
10	3,67	110,0	7699,57	7603,33	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2475,61	25630,34	2186,42
11	3,66	109,7	7680,33	7584,32	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2456,37	28086,71	2142,63
12	3,65	109,4	7661,12	7565,36	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2437,16	30523,87	2099,64
13	3,64	109,2	7641,97	7546,45	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2418,01	32941,88	2057,42
14	3,63	108,9	7622,87	7527,58	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2398,91	35340,79	2015,96
15	3,62	108,6	7603,81	7508,76	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2379,85	37720,64	1975,26
16	3,61	108,4	7584,80	7489,99	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2360,84	40081,48	1935,29
17	3,60	108,1	7565,84	7471,26	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2341,88	42423,36	1896,05
18	3,59	107,8	7546,92	7452,59	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2322,96	44746,32	1857,51
19	3,58	107,5	7528,06	7433,96	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2304,10	47050,42	1819,68

20	3,58	107,3	7509,24	7415,37	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2285,28	49335,69	1782,53		
21	3,57	107,0	7490,46	7396,83	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2266,50	51602,20	1746,07		
22	3,56	106,7	7471,74	7378,34	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2247,78	53849,97	1710,26		
23	3,55	106,5	7453,06	7359,89	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2229,10	56079,07	1675,11		
24	3,54	106,2	7434,42	7341,49	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2210,46	58289,53	1640,60		
25	3,53	105,9	7415,84	7323,14	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2191,88	60481,41	1606,72		
26	3,52	105,7	7397,30	7304,83	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2173,34	62654,75	1573,46		
27	3,51	105,4	7378,81	7286,57	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2154,85	64809,60	1540,81		
28	3,50	105,1	7360,36	7268,35	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2136,40	66946,00	1508,76		
29	3,50	104,9	7341,96	7250,18	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2118,00	69063,99	1477,30		
30	3,49	104,6	7323,60	7232,06	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2099,64	71163,64	1446,42		
31	3,48	104,4	7305,29	7213,98	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2081,33	73244,97	1416,11		
32	3,47	104,1	7287,03	7195,94	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2063,07	75308,04	1386,35		
33	3,46	103,8	7268,81	7177,95	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2044,85	77352,89	1357,14		
34	3,45	103,6	7250,64	7160,01	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2026,68	79379,58	1328,48		
35	3,44	103,3	7232,51	7142,11	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2008,55	81388,13	1300,34		
36	3,44	103,1	7214,43	7124,25	-5223,96	0	-5223,96	0	-5223,96	-5158,66	1990,47	83378,60	1272,73		
								Total inversión	0					VAN	67540,22
														TIR	2%

h) Flujo de caja con proyecto. La Tabla 26 representa los ingresos netos al considerar la implementación del SLA de BM por el método HL programado para 36 periodos equivalente a 36 meses. Por tanto, la ecuación (10) del flujo de caja tiene cuatro componentes:

$$\begin{aligned} & \textit{Flujo de caja con proyecto} \\ & = \textit{Ingresos} - \textit{Gastos por HL} - \textit{Gastos por BM} \quad (10) \\ & - \textit{Inversión} \end{aligned}$$

El flujo de caja con la implementación del proyecto en los 36 periodos muestra que:

La columna de ingresos en el primer trimestre es baja ya que produce por el método de HL, a partir del cuarto periodo los ingresos aumentan ya que la producción varía por la implementación del método de BM, cada periodo se realiza el cambio de SLA a dos pozos, hasta completar el cambio en los 14 pozos.

La columna de Gastos por HL a partir del primer hasta el décimo periodo se reduce de \$5223,96 a 0, debido a que en ese periodo se cambia el método de HL en el que operan los 14 pozos por el método de BM.

La columna de inversión a partir del cuarto hasta el décimo periodo la compañía invierte \$241597,72 para crear la infraestructura que requerirá el proyecto, en el periodo 21 la inversión se ha recuperado.

La columna de gastos de operación por BM a partir del cuarto periodo que inicia la ejecución del proyecto se incrementa mensualmente de \$204,12 que es el costo de operación por cada dos pozos hasta llegar a \$1428,84 siendo el costo de operación por los 14 pozos de BM.

Al flujo de caja con proyecto se aplicó actualización que consiste en determinar los flujos netos futuros de efectivo descontando la tasa de interés del 1,25% mensual (15% anual)

fijada por la compañía Pacifpetrol. De modo que los ingresos actualizados son \$534587,91 y los egresos actualizados de \$73281,35

Finalmente, el flujo de caja con la implementación del proyecto obtuvo una ganancia de \$467145,88 y un VAN de \$ 123141,76 con una tasa de interés del 1,25% mensual en un periodo de 36 meses para los 14 pozos que cambiaron del método de extracción de HL a BM en la sección 66 del campo GGV. Lo que indica que todos los flujos de caja que se desarrollaran en el futuro al aplicar el proyecto equivalen a que la compañía tenga \$ 123141,76 en el tiempo cero.

Por ende, queda demostrado que con la implementación del método de BM la producción aumenta un 70% en aquellos pozos que produce de la formación CPB, y santo tomas, y un 100% en pozos que producen de la formación Atlanta, con respecto a la producción que se presentaba con el método de HL, además que el VAN de \$ 123141,76 es superior al VAN de \$ 67540,22 obtenido sin implementar el proyecto. El TIR es de 4% obtenido a partir de los valores del flujo de caja para el periodo establecido, siendo este valor superior a la tasa de descuento mensual y superior a la TIR que se obtiene sin implementar el proyecto, esto indica que la inversión puede ser recuperada, concluyendo que resulta factible el cambio de SLA.

Tabla 30. Flujo de caja con proyecto para el SLA HL

PERÍODO (MES)	PRODUCCIÓN DIARIA BPD (declinación 0,25%)	PRODUCCIÓN MENSUAL BPD (declinación 0,25%)	INGRESOS (\$)	INGRESOS ACTUALIZADOS (\$)	GASTOS HERRAMIENTA LOCAL (\$)	GASTOS DE BOMBEO MECÁNICO (\$)	GASTOS DE OPERACIÓN (\$)	INVERSIÓN (\$)	EGRESOS (\$)	EGRESOS ACTUALIZADOS (\$)	FLUJO DE CAJA (\$)	FLUJO DE CAJA ACUMULADO (\$)	VALOR ACTUAL NETO (\$)
1	3,75	112,5	7875,00	7776,56	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2651,04	2651,04	2618,31
2	3,74	112,2	7855,31	7757,12	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2631,35	5282,39	2566,78
3	3,73	111,9	7835,67	7737,73	-5223,96	0	-5223,96	0	-5223,96	-5158,66	2611,71	7894,11	2516,17
4	4,74	142,1	9950,06	9825,69	-4477,68	-204,12	-4681,8	-34513,96	-4681,8	-4623,28	5268,26	13162,37	5012,88
5	5,49	164,6	11521,13	11377,11	-3731,4	-408,24	-4139,64	-34513,96	-4139,64	-4087,89	7381,49	20543,85	6936,95
6	6,49	194,8	13636,82	13466,36	-2985,12	-612,36	-3597,48	-34513,96	-3597,48	-3552,51	10039,34	30583,20	9318,27
7	6,65	199,6	13971,98	13797,33	-2238,84	-816,48	-3055,32	-34513,96	-3055,32	-3017,13	10916,66	41499,86	10007,48
8	6,98	209,5	14663,25	14479,96	-1492,56	-1020,6	-2513,16	-34513,96	-2513,16	-2481,75	12150,09	53649,95	11000,67
9	7,61	228,3	15982,94	15783,16	-746,28	-1224,72	-1971	-34513,96	-1971	-1946,36	14011,94	67661,89	12529,77
10	7,98	239,4	16758,00	16548,53	0	-1428,84	-1428,84	-34513,96	-1428,84	-1410,98	15329,16	82991,05	13538,42
11	7,96	238,8	16716,11	16507,15	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15287,27	98278,32	13334,74
12	7,94	238,2	16674,31	16465,89	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15245,47	113523,79	13134,11
13	7,92	237,6	16632,63	16424,72	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15203,79	128727,58	12936,49
14	7,90	237,0	16591,05	16383,66	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15162,21	143889,79	12741,84
15	7,88	236,4	16549,57	16342,70	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15120,73	159010,52	12550,10
16	7,86	235,8	16508,20	16301,84	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15079,36	174089,87	12361,25
17	7,84	235,2	16466,93	16261,09	0	-1428,84	-1428,84	0	-1428,84	-1410,98	15038,09	189127,96	12175,23
18	7,82	234,7	16425,76	16220,44	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14996,92	204124,88	11992,00
19	7,80	234,1	16384,69	16179,88	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14955,85	219080,73	11811,51

20	7,78	233,5	16343,73	16139,44	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14914,89	233995,62	11633,74	
21	7,76	232,9	16302,87	16099,09	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14874,03	248869,65	11458,64	
22	7,74	232,3	16262,12	16058,84	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14833,28	263702,93	11286,16	
23	7,72	231,7	16221,46	16018,69	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14792,62	278495,55	11116,28	
24	7,71	231,2	16180,91	15978,65	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14752,07	293247,62	10948,94	
25	7,69	230,6	16140,45	15938,70	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14711,61	307959,23	10784,12	
26	7,67	230,0	16100,10	15898,85	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14671,26	322630,49	10621,76	
27	7,65	229,4	16059,85	15859,10	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14631,01	337261,51	10461,85	
28	7,63	228,9	16019,70	15819,46	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14590,86	351852,37	10304,34	
29	7,61	228,3	15979,65	15779,91	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14550,81	366403,18	10149,19	
30	7,59	227,7	15939,70	15740,46	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14510,86	380914,05	9996,37	
31	7,57	227,1	15899,86	15701,11	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14471,02	395385,06	9845,85	
32	7,55	226,6	15860,11	15661,85	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14431,27	409816,33	9697,58	
33	7,53	226,0	15820,46	15622,70	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14391,62	424207,95	9551,54	
34	7,51	225,4	15780,90	15583,64	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14352,06	438560,01	9407,70	
35	7,50	224,9	15741,45	15544,68	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14312,61	452872,62	9266,01	
36	7,48	224,3	15702,10	15505,82	0	-1428,84	-1428,84	0	-1428,84	-1410,98	14273,26	467145,88	9126,45	
									Total inversión	-241597,72			VAN	123141,76
													TIR	4%

i) **Análisis comparativo de flujos de caja.** Realizar un análisis comparativo de los flujos de caja del proyecto permite interpretar la diferencia entre la situación actual y la posterior si se implementa el proyecto. En la Figura 72 muestra el comportamiento actual si no se implementa el método de BM por el método de HL.




Figura 72. Gráfico de flujo de caja sin implementar el proyecto

Sin embargo, al implementar el proyecto el resultado que se obtiene se muestra en la Figura 73




Figura 73. Gráfico de flujo de caja con la implementación proyecto

Finalmente, en la Figura 74 se observa el resultado que tiene la implementación del BM sobre el método de extracción actual que es la herramienta de los 14 pozos de la sección 66 del Campo GGV. La tendencia de la línea amarilla indica que los ingresos por producción al implementar el método de BM son superiores a los del método de HL, es decir, que si se producía con 112,5 bls por mes con ingreso de \$7875, en la implementación del proyecto se tendría 239,4 bls por mes con ingreso de \$16758. La tendencia de la línea celeste indica que los gastos operativos por BM son inferiores a los del método de HL y solo en el primer trimestre se tienen los mismos gastos, debido a que partir del cuarto periodo se inicia la implementación del proyecto. La tendencia de la línea verde indica el comportamiento del flujo de caja con la implementación del método de BM donde podemos observar la rentabilidad económica comparada con el flujo de caja sin implementar el proyecto.

En conclusión, implementar el método de BM en los 14 pozos que operan por el método de HL es factible y los resultados obtenidos indican un aumento en la producción, ganancias y el VAN.




Figura 74. Gráfico comparativo de flujos de caja

CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

- En la sección 66 hay un total de 60 pozos, la producción de petróleo se obtiene de 32 pozos mediante tres tipos de sistemas de levantamiento artificial mismos que fueron utilizados por el algoritmo a fin de seleccionar un único sistema, estos son: bombeo mecánico, swab y herramienta local, los 28 pozos restantes no fueron considerados debido a que presentan problemas, razón por la cual se encuentran cerrados y uno de ellos es pozos inyector.
- Los sistemas de levantamiento artificial con el que operan los pozos de la sección 66 presentan sus respectivas ventajas y desventajas que los diferencian uno de otro. El bombeo mecánico es un sistema que ofrece mejores resultados debido a puede ser utilizado prácticamente durante toda la vida productiva del pozo, además los costos de operaciones son bajos, por el contrario, los sistemas herramienta local y swab presenta altos costos de operación y mantenimiento, este último al evaluar el pozo requiere bajar tubería lo cual demanda un gasto extra, siendo el sistema de levantamiento artificial más costoso.
- El uso de un algoritmo supervisado de machine learning basado en árbol de decisión permite obtener mejor predicción en comparación a modelos de regresión lineal y regresión polinómica. El objetivo propuesto se cumple realizando una clasificación de datos con un análisis de las variables disponibles en el dataset, dicha tarea la resuelven los algoritmos de clasificación puesto que estos predicen resultados de acuerdo con el entrenamiento y la variable dependiente que ha recibido.

- La predicción del algoritmo árbol de decisión da como resultado que el sistema de levantamiento artificial óptimo a implementar en toda la sección 66 es bombeo mecánico, porque los pozos que operan con este sistema obtuvieron una mayor tasa de producción durante el periodo 2016-2020 en comparación a los pozos que producen con otros sistemas de levantamiento artificial, y a su vez generaron menor gasto de operación y mantenimiento debido a que las intervenciones que se realizan en los pozos son de bajo costo, además se economiza dinero en combustible, grasas, lubricantes y repuestos.
- Implementar el proyecto es rentable puesto que el flujo de caja obtuvo una ganancia de \$898148,85 y un VAN de \$ 567377,51 con una TIR del 14% frente a la tasa de interés mensual de 1,25% en un periodo de 36 meses para los 8 pozos que cambiaron del método de extracción de swab a bombeo mecánico y el flujo de caja proyectado a 36 meses para los 14 pozos que cambiaron del método de extracción de herramienta local a bombeo mecánico obtuvo una ganancia de \$467145,88 y un VAN de \$ 123141,76 con una TIR del 4% frente a la tasa de interés mensual de 1,25%. En conclusión, el cambio del sistema de levantamiento artificial es económicamente factible.

5.2 RECOMENDACIONES

- Para el levantamiento de información se recomienda mantener actualizado la base de datos y que lo mencionado presente una cantidad superior o igual a 5 años para que el algoritmo al momento de entrenar y aprender con la finalidad de garantizar una estimación efectiva y precisa en base a ese dataset.
- Se recomienda a la empresa operadora realizar el cambio de sistema de levantamiento artificial de swab y herramienta local que presenta la sección 66 por el sistema de levantamiento artificial de bombeo mecánico como método de extracción.
- Comparar el uso de la técnica machine learning con otras herramientas tecnológicas y evaluar los resultados.
- Realizar estudios similares al del trabajo presente, especialmente a campos maduros para optimizar la producción y minimizar los gastos asimismo que se estudien los motivos y razones por las cuales el sistema de levantamiento artificial de cierto campo es el predominante.
- Contar con una activa participación por parte de los ingenieros de producción en los procedimientos regulares para la inspección y evaluación de los elementos del sistema de levantamiento artificial por bombeo mecánico.

REFERENCIAS BIBLIOGRÁFICAS

- Rovirosa Martínez, A. (2015 de Septiembre de 2020). Global Energy. Obtenido de La Inteligencia Artificial, apuesta obligada para la industria del Petróleo:
<https://globalenergy.mx/noticias-especiales/columnas/la-inteligencia-artificial-apuesta-obligada-para-la-industria-del-petroleo/>
- Alandete, D. (27 de Octubre de 2011). El País. Obtenido de John McCarthy, el arranque de la inteligencia artificial:
https://elpais.com/diario/2011/10/27/necrologicas/1319666402_850215.html
- Alonso, R. (8 de Abril de 2020). Hard Zone. Obtenido de
<https://hardzone.es/tutoriales/rendimiento/diferencias-ia-deep-machine-learning/>
- Americas. (16 de septiembre de 2019). bnamericas. Obtenido de Industria de petróleo y gas liderará uso de inteligencia artificial:
<https://www.bnamericas.com/es/reportajes/industria-de-petroleo-y-gas-liderara-uso-de-inteligencia-artificial>
- Beggs, H. D. (2003). Production optimization using nodal analysis. Oklahoma: OGCI and Petroskills Publications .
- Bogachev, I. (11 de Febrero de 2021). Whatsnew. Obtenido de LA INTELIGENCIA ARTIFICIAL EN LA INDUSTRIA: ANÁLISIS DE PREDICCIÓN Y SISTEMAS DE TOMA DE DECISIONES:
<https://www.whatsnew.com/2021/02/11/la-inteligencia-artificial-en-la-industria-analisis-de-prediccion-y-sistemas-de-toma-de-decisiones/>
- Calderón Enríquez, A. (2013). Repositorio Dspace UPSE. Obtenido de
<https://repositorio.upse.edu.ec/xmlui/handle/46000/2426>
- Call, J. (17 de Mayo de 2015). OpenMind . Obtenido de
<https://www.bbvaopenmind.com/tecnologia/inteligencia-artificial/alan-turing-y-el-sueno-de-la-inteligencia-artificial/>
- Camargo, E., & Aguilar , J. (Marzo de 2012). researchgate. Obtenido de Supervisión Inteligente para Mejorar el Desempeño de la Producción Industrial en Pozos Petroleros:
[https://www.researchgate.net/publication/288831891_Supervision_Inteligente_p ara_Mejorar_el_Desempeno_de_la_Produccion_Industrial_en_Pozos_Petroleros](https://www.researchgate.net/publication/288831891_Supervision_Inteligente_para_Mejorar_el_Desempeno_de_la_Produccion_Industrial_en_Pozos_Petroleros)
- Colina, E. (17 de octubre de 2014). MASKANA. Obtenido de
http://dspace.ucuenca.edu.ec/bitstream/123456789/21348/1/MATCH'14_08_Ram%C3%ADrez%20&%20Colina.pdf

- Cornieles, P. (3 de Septiembre de 2019). ia-latam. Obtenido de El petróleo del siglo XXI: los datos en la inteligencia artificial: <https://ia-latam.com/2019/09/03/el-petroleo-del-siglo-xxi-los-datos-en-la-inteligencia-artificial/>
- Cruz. (2019). KPMG. Obtenido de Transformación digital en la industria de petróleo y gas: <https://www.delineandoestrategias.com.mx/blog-de/transformacion-digital-en-la-industria-de-petroleo-y-gas>
- De la Cruz, A., & Barceló, G. (octubre de 2009). Scielo. Obtenido de http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0378-18442009001000007
- Díaz, G. (2018). depetroleo. Obtenido de <https://depetroleo.com/petroleo-2-0-inteligencia-artificial-para-mejorar-la-produccion/>
- Galvis, A. y. (25 de febrero de 2011). Repositorio UNIRIOJA. Obtenido de <https://dialnet.unirioja.es/descarga/articulo/4811231.pdf>
- Garavito Arena , F. (2017). Universidad Militar Nueva Granada. Obtenido de Inteligencia Artificial como herramienta en la detección de fallas en los equipos de levantamiento Mécanico en la industria Petrolera: <https://repository.unimilitar.edu.co/bitstream/handle/10654/16291/Fre%20dy%20A.%20Garavito%20Arenas%202017.pdf?sequence=2&isAllow%20ed=y>
- García , J., & Martínez , E. (5 de enero de 2006). DSpace en ESPOL. Obtenido de <https://www.dspace.espol.edu.ec/handle/123456789/4546>
- García, P., & Villón, M. (2014). Repositorio Dspace UPSE. Obtenido de <https://repositorio.upse.edu.ec/xmlui/handle/46000/1666>
- Geographic, N. (5 de Agosto de 2019). Breve historia visual de la inteligencia artificial. National Geographic España, 3. Obtenido de Breve historia visual de la inteligencia artificial: https://www.nationalgeographic.com.es/ciencia/breve-historia-visual-inteligencia-artificial_14419
- Julia, J. (6 de Marzo de 2021). Inteligenciaes. Obtenido de <https://inteligenciaes.com/que-es-la-ia-todo-lo-que-necesita-saber-sobre-inteligencia-artificial/>
- Kaplan, A., & Haenlein, M. (January de 2019). Science Direct. Obtenido de Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence: <https://www.sciencedirect.com/science/article/abs/pii/S0007681318301393?via%3Dihub>
- Martínez, Y. L. (15 de febrero de 2021). Lumieres - Repositorio institucional Universidad de América. Obtenido de <https://repository.uamerica.edu.co/bitstream/20.500.11839/8264/1/5161473-2021-1-IP.pdf>

- Mauro, J. (2021). aura Quantic. Obtenido de <https://www.auraquantic.com/es/automatizacion-inteligente/>
- Mitchell, T. M. (1997). Machine Learning. Pittsburgh: McGraw-Hill.
- Montes. (2019). Busines Insider. Obtenido de <https://www.businessinsider.es/shell-aplica-herramientas-inteligencia-artificial-microsoft-445645>
- Ng, A. (6 de Febrero de 2019). How to Choose Your First AI Project. Obtenido de Harvard Business Review : <https://hbr.org/2019/02/how-to-choose-your-first-ai-project>
- Ochoa, I. (9 de Septiembre de 2019). El argumento del Capital . Obtenido de <https://igorochoa.net/2019/09/09/que-es-machine-learning-aprendizaje-automatico/>
- Oña , J., & Armijos, D. (2018). Repositorio Dspace UPSE. Obtenido de <https://repositorio.upse.edu.ec/xmlui/handle/46000/4621>
- Ounsaku, T., Thum, S., & Wiwat , P. (Enero de 2019). Researchgate. Obtenido de Artificial Lift Selection Using Machine Learning: https://www.researchgate.net/publication/331871652_Artificial_Lift_Selection_Using_Machine_Learning
- Pacifpetrol. (2021). Levantamiento de información . Santa Elena.
- Pillasagua , J., & Rodríguez , D. (2014). Repositorio UPSE. Obtenido de <https://repositorio.upse.edu.ec/bitstream/46000/1664/1/ESTUDIO%20DE%20ACTIBILIDAD%20PARA%20LA%20IMPLEMENTACI%C3%93N%20DEL%20SISTEMA%20DE%20BOMBAS%20DE%20CAVIDADES%20PROGRESIVAS%20EN%20EL%20CAMPO%20%E2%80%9CGUSTAVO%20GALINDO%20VELASCO%E2%80%9D%20UBICADO%2>
- Riverol, A. (8 de Marzo de 2021). somosinnovacion. Obtenido de Posibilidades de las Plataformas Petroleras e Inteligencia Artificial en Chile: <https://www.somosinnovacion.lat/posibilidades-de-las-plataformas-petroleras-e-inteligencia-artificial-en-chile/>
- Russell, S., & Norvig, P. (2004). Inteligencia Artificial Un enfoque Moderno (Vol. 2). Madrid: Pearson Educacion S.A.
- Sánchez Ron , J. (17 de Mayo de 2015). OpenMind BBVA. Obtenido de Alan Turing y el sueño de la inteligencia artificial: <https://www.bbvaopenmind.com/tecnologia/inteligencia-artificial/alan-turing-y-el-sueno-de-la-inteligencia-artificial/>
- Sanseviero, O. (30 de Enero de 2018). AI Learners. Obtenido de <https://medium.com/ai-learners/ai-en-3-minutos-tipos-de-machine-learning-945b708ac78>

- Services, W. B. (17 de Abril de 2019). Ecosistema Huawei. Obtenido de <https://ecosistemahuawei.xataka.com/que-entendemos-hoy-inteligencia-artificial-hoy-que-englobara-2025/>
- Slav, I. (24 de Diciembre de 2018). oilchannel. Obtenido de El futuro de la inteligencia artificial en Pétroleo y Gas: <https://www.oilchannel.tv/noticias/el-futuro-de-la-inteligencia-artificial-en-petroleo-y-gas>
- Tituaña, F. T. (Julio de 2018). Dspace UCE. Obtenido de <http://www.dspace.uce.edu.ec/handle/25000/16027>
- Veloz , C., & Velastegui , L. (febrero de 2007). Repositorio Digital - EPN. Obtenido de <https://bibdigital.epn.edu.ec/handle/15000/133>

ANEXOS

Anexo A: Instalación de librerías a utilizar durante el desarrollo del algoritmo

Instalar Python 3, con las teclas Windows + R abrir el comando cmd con el cual vamos a descargar el entorno de trabajo para desarrollar el algoritmo y las diferentes librerías a usar. Ver Figura A 75





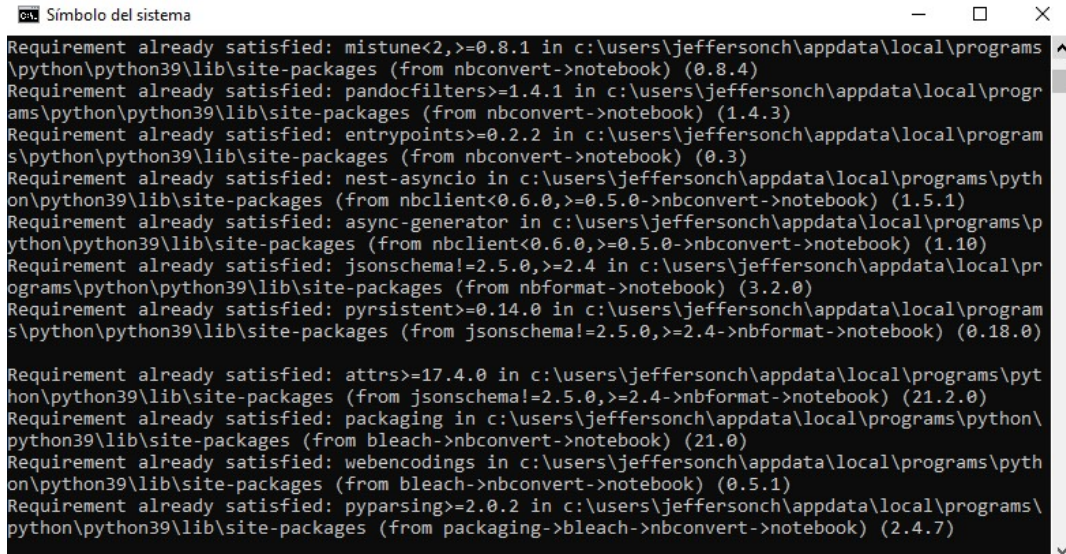
Figura A 75. Herramienta ejecutar de Windows

Con ayuda del cmd se instala un jupyter notebook escribiendo “pip install notebook” y de manera automática se nos instalará. Ver Figura A 76

Figura A 76. Procedimiento para instalar "jupyter"



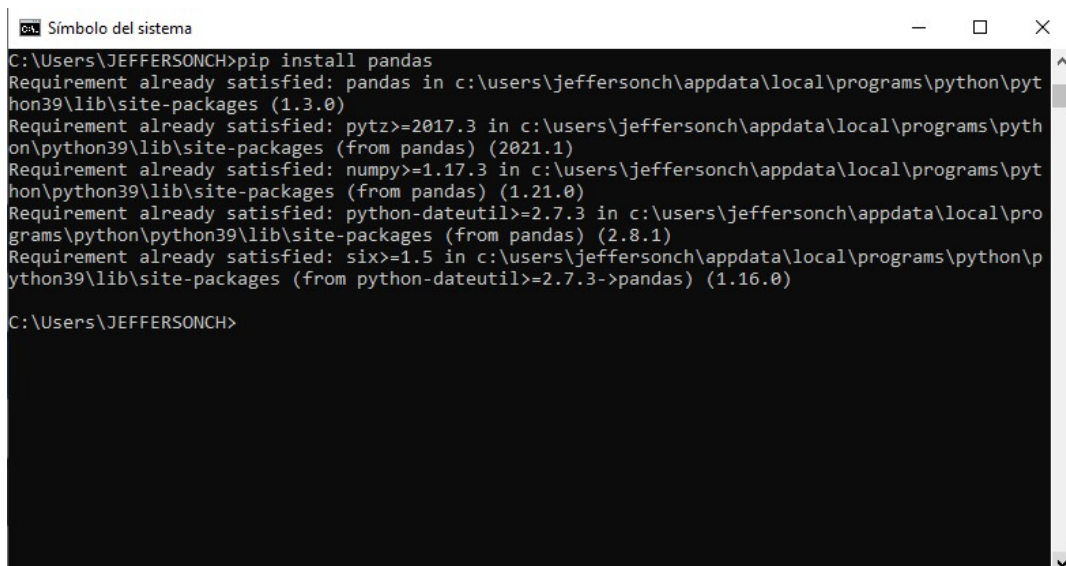
El mensaje “requirement already satisfied” nos confirma que la instalación fue exitosa, y podremos avanzar en la instalación de las librerías a utilizar en el desarrollo del algoritmo. Ver Figura A 77



```
Símbolo del sistema
Requirement already satisfied: mistune<2,>=0.8.1 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbconvert->notebook) (0.8.4)
Requirement already satisfied: pandocfilters>=1.4.1 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbconvert->notebook) (1.4.3)
Requirement already satisfied: entrypoints>=0.2.2 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbconvert->notebook) (0.3)
Requirement already satisfied: nest-asyncio in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbclient<0.6.0,>=0.5.0->nbconvert->notebook) (1.5.1)
Requirement already satisfied: async-generator in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbclient<0.6.0,>=0.5.0->nbconvert->notebook) (1.10)
Requirement already satisfied: jsonschema!=2.5.0,>=2.4 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from nbformat->notebook) (3.2.0)
Requirement already satisfied: pyparsing>=0.14.0 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from jsonschema!=2.5.0,>=2.4->nbformat->notebook) (0.18.0)
Requirement already satisfied: attrs>=17.4.0 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from jsonschema!=2.5.0,>=2.4->nbformat->notebook) (21.2.0)
Requirement already satisfied: packaging in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from bleach->nbconvert->notebook) (21.0)
Requirement already satisfied: webencodings in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from bleach->nbconvert->notebook) (0.5.1)
Requirement already satisfied: pyparsing>=2.0.2 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from packaging->bleach->nbconvert->notebook) (2.4.7)
```

Figura A 77. Instalación del entorno de trabajo "jupyter"

Una vez instalado jupyter se debe instalar las librerías las cuales ayudan a codificar lenguajes de programación. Entre las librerías a instalar están; sklearn, matplotlib, openpyxl y pandas. Ver Figura A 78

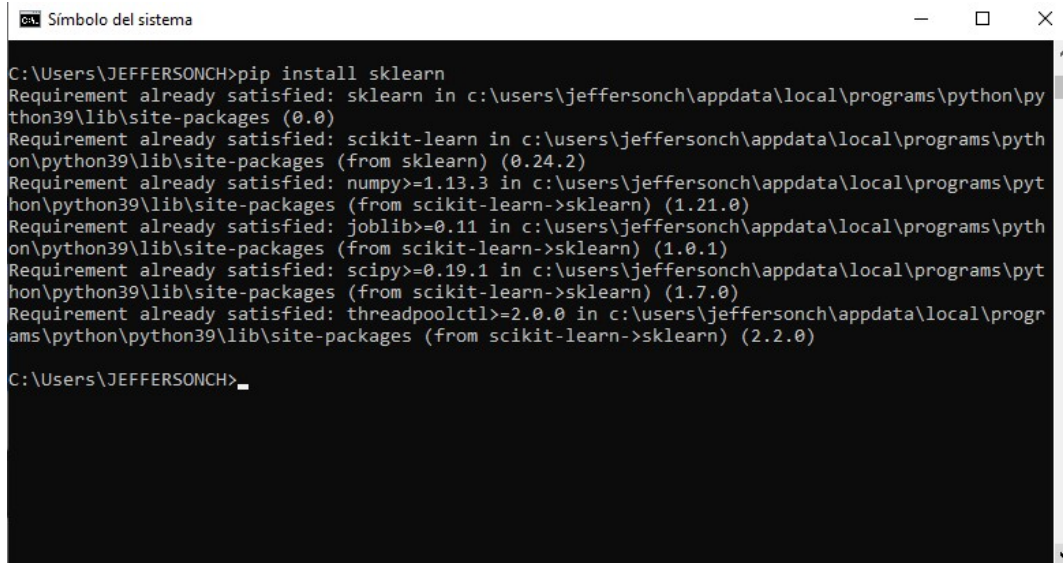


```
Símbolo del sistema
C:\Users\JEFFERSONCH>pip install pandas
Requirement already satisfied: pandas in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (1.3.0)
Requirement already satisfied: pytz>=2017.3 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from pandas) (2021.1)
Requirement already satisfied: numpy>=1.17.3 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from pandas) (1.21.0)
Requirement already satisfied: python-dateutil>=2.7.3 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from pandas) (2.8.1)
Requirement already satisfied: six>=1.5 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from python-dateutil>=2.7.3->pandas) (1.16.0)
C:\Users\JEFFERSONCH>
```

Figura A 78. Instalación de la librería "pandas".

Siguiente, se procede a la instalación de la librería escribiendo “pip install + sklearn”.

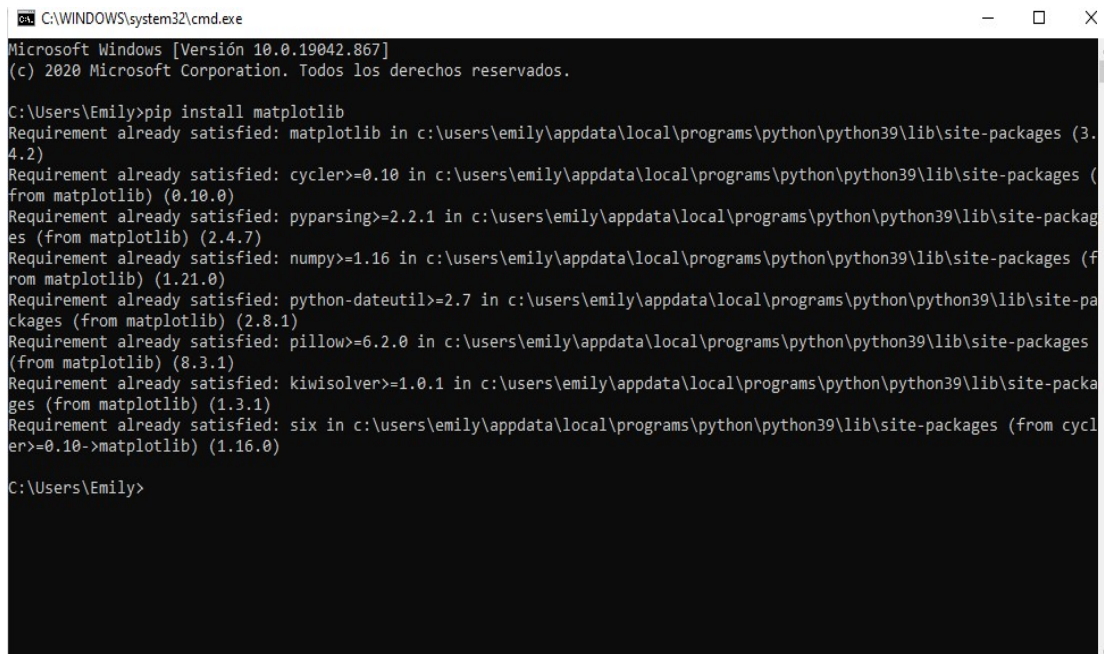
Ver Figura A 79



```
Símbolo del sistema
C:\Users\JEFFERSONCH>pip install sklearn
Requirement already satisfied: sklearn in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (0.0)
Requirement already satisfied: scikit-learn in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from sklearn) (0.24.2)
Requirement already satisfied: numpy>=1.13.3 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from scikit-learn->sklearn) (1.21.0)
Requirement already satisfied: joblib>=0.11 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from scikit-learn->sklearn) (1.0.1)
Requirement already satisfied: scipy>=0.19.1 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from scikit-learn->sklearn) (1.7.0)
Requirement already satisfied: threadpoolctl>=2.0.0 in c:\users\jeffersonch\appdata\local\programs\python\python39\lib\site-packages (from scikit-learn->sklearn) (2.2.0)
C:\Users\JEFFERSONCH>
```

Figura A 79. Instalación de la Librería "sklearn"

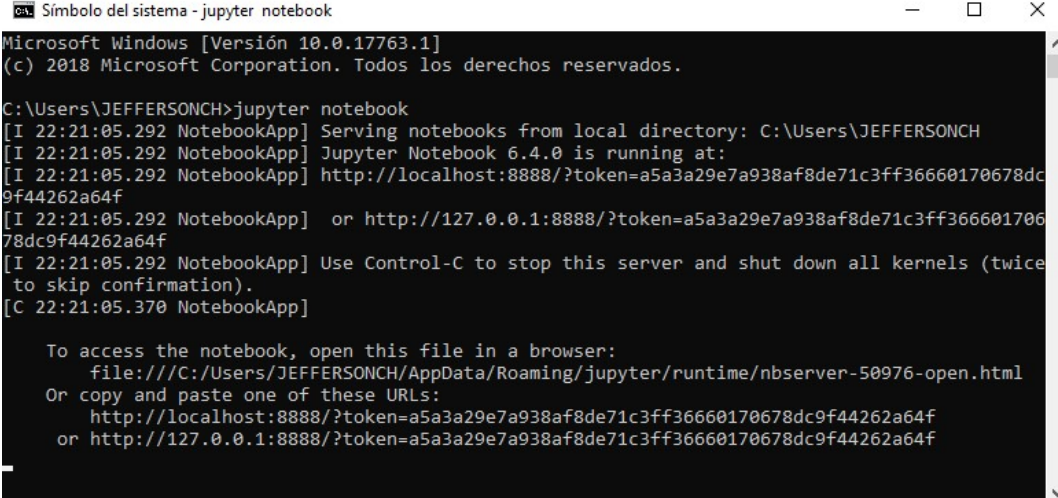
Sucesivo, se procede a la instalación de la librería que permite visualizar los datos de forma gráfica escribiendo “pip install + matplotlib”. Ver Figura A 80



```
C:\WINDOWS\system32\cmd.exe
Microsoft Windows [Versión 10.0.19042.867]
(c) 2020 Microsoft Corporation. Todos los derechos reservados.
C:\Users\Emily>pip install matplotlib
Requirement already satisfied: matplotlib in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (3.4.2)
Requirement already satisfied: cycler>=0.10 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (0.10.0)
Requirement already satisfied: pyparsing>=2.2.1 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (2.4.7)
Requirement already satisfied: numpy>=1.16 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (1.21.0)
Requirement already satisfied: python-dateutil>=2.7 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (2.8.1)
Requirement already satisfied: pillow>=6.2.0 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (8.3.1)
Requirement already satisfied: kiwisolver>=1.0.1 in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from matplotlib) (1.3.1)
Requirement already satisfied: six in c:\users\emily\appdata\local\programs\python\python39\lib\site-packages (from cycler>=0.10->matplotlib) (1.16.0)
C:\Users\Emily>
```

Figura A 80. Instalación de la Librería "matplotlib"

Una vez instalado el entorno de trabajo junto con las librerías se ejecuta “jupyter notebook” para dar inicio al desarrollo del algoritmo. Ver Figura A 81



```
Símbolo del sistema - jupyter notebook
Microsoft Windows [Versión 10.0.17763.1]
(c) 2018 Microsoft Corporation. Todos los derechos reservados.

C:\Users\JEFFERSONCH>jupyter notebook
[I 22:21:05.292 NotebookApp] Serving notebooks from local directory: C:\Users\JEFFERSONCH
[I 22:21:05.292 NotebookApp] Jupyter Notebook 6.4.0 is running at:
[I 22:21:05.292 NotebookApp] http://localhost:8888/?token=a5a3a29e7a938af8de71c3ff36660170678dc9f44262a64f
[I 22:21:05.292 NotebookApp] or http://127.0.0.1:8888/?token=a5a3a29e7a938af8de71c3ff36660170678dc9f44262a64f
[I 22:21:05.292 NotebookApp] Use Control-C to stop this server and shut down all kernels (twice to skip confirmation).
[C 22:21:05.370 NotebookApp]

To access the notebook, open this file in a browser:
file:///C:/Users/JEFFERSONCH/AppData/Roaming/jupyter/runtime/nbserver-50976-open.html
Or copy and paste one of these URLs:
http://localhost:8888/?token=a5a3a29e7a938af8de71c3ff36660170678dc9f44262a64f
or http://127.0.0.1:8888/?token=a5a3a29e7a938af8de71c3ff36660170678dc9f44262a64f
```

Figura A 81. Comando para abrir el entorno de trabajo "jupyter notebook"

Instalación de Librerías complementarias. Ver Figura A 82

```
pip install seaborn
pip install graphviz
pip install lib
pip install image
pip install pydotplus
pip install tree
pip install metrics
pip install linear
pip install model
pip install model
pip install selection |
pip install test
pip install DecisionTreeClassifier
pip install accuracy
pip install score
pip install classification
pip install report
pip install confusion
pip install matrix
pip install export
pip install graphviz
pip install cross
pip install LabelEncoder
pip install plotly
pip install express
```

Figura A 82. Librerías complementarias

Inmediatamente se abre una pestaña del navegador web predefinido, por medio del cual se crea y ejecuta el algoritmo. Esta pestaña muestra una lista de notebooks, archivos y directorios perteneciente a la carpeta donde inició jupyter. Ver Figura A 82




Figura A 9. Pestaña correspondiente al home de jupyter

Para crear un notebook, clic en el botón new y dentro de las opciones elegir Python. Ver Figura A 10



Figura A 10. Crear un notebook

Anexo B: Producción acumulada y gastos en el periodo 2016-2020

Tabla B 31. Producción y gastos de los pozos productores

Pozos	Producción acumulada	Gasto en combustible	Gasto en grasas y lubricantes	Gasto en Mantenimiento de equipo	Gastos totales	SLA
ANC0162	1095,00	16551,6	2526,6	15554,28	34632,48	SW
ANC0163	2573,25	18206,76	3031,92	16665,3	37903,98	SW
ANC0589	3358,00	26151,528	3542,56	44440,8	74134,89	SW
ANC0655	1697,25	24827,4	3031,92	17776,32	45635,64	SW
ANC1493	1259,25	18537,792	3284,58	46662,84	68485,21	SW
ANC1648	1679,00	19034,34	3789,9	15776,484	38600,72	SW
ANC1678	848,62	13241,28	1263,3	13776,648	28281,23	SW
ANC3007	1642,50	24827,4	3284,58	43329,78	71441,76	SW
ANC0420	415,18	5274	1359	14913,6	21546,60	HL
ANC0424	424,31	5326,74	1494,9	16404,96	23226,60	HL
ANC0434	428,87	5379,48	1630,8	15211,872	22222,15	HL
ANC0582	209,87	2637	815,4	7456,8	10909,20	HL
ANC0667	416,10	5353,11	1386,18	15137,304	21876,59	HL
ANC1073	1245,56	14767,2	2582,1	22370,4	39719,70	HL
ANC1393	288,95	3111,66	543,6	8799,024	12454,28	HL
ANC1395	109,50	1318,5	339,75	3728,4	5386,65	HL
ANC1396	223,86	2689,74	543,6	7605,936	10839,28	HL
ANC1703	577,91	5801,4	1494,9	16404,96	23701,26	HL
ANC1713	411,72	5537,7	1223,1	15659,28	22420,08	HL
ANCFA02	1119,33	14767,2	2718	34003,008	51488,21	HL
ANCFA13	54,75	1318,5	339,75	3728,4	5386,65	HL
ANCFA22	821,25	10548	1902,6	29827,2	42277,80	HL
ANC0437	820,25	421,8	934,2	39300	40656,00	BM
ANC0446	3285,00	843,6	1681,56	4323	6848,16	BM
ANC0458	1660,75	379,62	747,36	3537	4663,98	BM
ANC0461	2573,25	641,136	1681,56	5973,6	8296,30	BM
ANC0465	8395,00	2952,6	2802,6	19650	25405,20	BM
ANC0504	6935,00	1265,4	1961,82	59343	62570,22	BM
ANC0508	1733,75	421,8	934,2	3930	5286,00	BM
ANC0585	5480,47	1181,04	1961,82	19650	22792,86	BM
ANC0656	1733,75	421,8	934,2	3930	5286,00	BM

Anexo C: Ingresos en función de la producción total de pozos

Tabla C 32. Ingresos por producción mensual del SLA SW

PERÍODO	PRODUCCIÓN	INGRESOS
	MENSUAL BPD (declinación 0,25%)	
1	235,80	16506,00
2	235,21	16464,74
3	234,62	16423,57
4	234,04	16382,51
5	233,45	16341,56
6	232,87	16300,70
7	232,29	16259,95
8	231,70	16219,30
9	231,13	16178,75
10	230,55	16138,31
11	229,97	16097,96
12	229,40	16057,72
13	228,82	16017,57
14	228,25	15977,53
15	227,68	15937,58
16	227,11	15897,74
17	226,54	15858,00
18	225,98	15818,35
19	225,41	15778,81
20	224,85	15739,36
21	224,29	15700,01
22	223,73	15660,76
23	223,17	15621,61
24	222,61	15582,55
25	222,05	15543,60
26	221,50	15504,74
27	220,94	15465,98
28	220,39	15427,31
29	219,84	15388,74
30	219,29	15350,27
31	218,74	15311,90
32	218,19	15273,62
33	217,65	15235,43
34	217,10	15197,34
35	216,56	15159,35
36	216,02	15121,45

Tabla C 33. Ingresos por producción mensual al implementar BM por SW

PERÍODO	PRODUCCIÓN MENSUAL	
	BPD (declinación 0,25%)	INGRESOS
1	235,80	16506,00
2	235,21	16464,74
3	234,62	16423,57
4	280,70	19648,76
5	343,54	24047,73
6	380,35	26624,27
7	411,77	28823,76
8	410,74	28751,70
9	409,71	28679,82
10	408,69	28608,12
11	407,67	28536,60
12	406,65	28465,26
13	405,63	28394,10
14	404,62	28323,11
15	403,60	28252,30
16	402,60	28181,67
17	401,59	28111,22
18	400,58	28040,94
19	399,58	27970,84
20	398,58	27900,91
21	397,59	27831,16
22	396,59	27761,58
23	395,60	27692,18
24	394,61	27622,95
25	393,63	27553,89
26	392,64	27485,00
27	391,66	27416,29
28	390,68	27347,75
29	389,71	27279,38
30	388,73	27211,18
31	387,76	27143,16
32	386,79	27075,30
33	385,82	27007,61
34	384,86	26940,09
35	383,90	26872,74
36	382,94	26805,56

Tabla C 3. Ingresos por producción mensual del SLA HL

PERÍODO	PRODUCCIÓN	
	MENSUAL BPD (declinación 0,25%)	INGRESOS
1	112,5	7875,00
2	112,2	7855,31
3	111,9	7835,67
4	111,7	7816,09
5	111,4	7796,54
6	111,1	7777,05
7	110,8	7757,61
8	110,5	7738,22
9	110,3	7718,87
10	110,0	7699,57
11	109,7	7680,33
12	109,4	7661,12
13	109,2	7641,97
14	108,9	7622,87
15	108,6	7603,81
16	108,4	7584,80
17	108,1	7565,84
18	107,8	7546,92
19	107,5	7528,06
20	107,3	7509,24
21	107,0	7490,46
22	106,7	7471,74
23	106,5	7453,06
24	106,2	7434,42
25	105,9	7415,84
26	105,7	7397,30
27	105,4	7378,81
28	105,1	7360,36
29	104,9	7341,96
30	104,6	7323,60
31	104,4	7305,29
32	104,1	7287,03
33	103,8	7268,81
34	103,6	7250,64
35	103,3	7232,51
36	103,1	7214,43

Tabla C 4. Ingresos por producción mensual al implementar BM por HL

PERÍODO	PRODUCCIÓN MENSUAL	
	BPD (declinación 0,25%)	INGRESOS
1	112,5	7875,00
2	112,2	7855,31
3	111,9	7835,67
4	142,1	9950,06
5	164,6	11521,13
6	194,8	13636,82
7	199,6	13971,98
8	209,5	14663,25
9	228,3	15982,94
10	239,4	16758,00
11	238,8	16716,11
12	238,2	16674,31
13	237,6	16632,63
14	237,0	16591,05
15	236,4	16549,57
16	235,8	16508,20
17	235,2	16466,93
18	234,7	16425,76
19	234,1	16384,69
20	233,5	16343,73
21	232,9	16302,87
22	232,3	16262,12
23	231,7	16221,46
24	231,2	16180,91
25	230,6	16140,45
26	230,0	16100,10
27	229,4	16059,85
28	228,9	16019,70
29	228,3	15979,65
30	227,7	15939,70
31	227,1	15899,86
32	226,6	15860,11
33	226,0	15820,46
34	225,4	15780,90
35	224,9	15741,45
36	224,3	15702,10

**Anexo D: Producción mensual de los pozos que operan con HL durante el periodo
2016-2020**

Tabla D 34. Producción total de los pozos con SLA HL 2016 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0420	7,44	7,18	7,41	7,39	7,37	7,35	7,33	7,32	7,30	7,28	7,26	7,24
ANC0424	7,44	7,18	7,41	7,39	7,37	7,35	7,33	7,32	7,30	7,28	7,26	7,24
ANC0434	7,44	7,18	7,41	7,39	7,37	7,35	7,33	7,32	7,30	7,28	7,26	7,24
ANC0582	3,72	3,59	3,70	3,69	3,69	3,68	3,67	3,66	3,65	3,64	3,63	3,62
ANC0667	7,15	6,89	7,11	7,09	7,08	7,06	7,04	7,02	7,01	6,99	6,97	6,95
ANC1073	22,33	21,54	22,22	22,17	22,11	22,06	22,00	21,95	21,89	21,84	21,78	21,73
ANC1393	4,96	4,79	4,94	4,93	4,91	4,90	4,89	4,88	4,86	4,85	4,84	4,83
ANC1395	1,99	1,91	1,98	1,97	1,97	1,96	1,96	1,95	1,95	1,94	1,94	1,93
ANC1396	3,97	3,83	3,95	3,94	3,93	3,92	3,91	3,90	3,89	3,88	3,87	3,86
ANC1703	9,93	9,57	9,88	9,85	9,83	9,80	9,78	9,75	9,73	9,71	9,68	9,66
ANC1713	7,15	6,89	7,11	7,09	7,08	7,06	7,04	7,02	7,01	6,99	6,97	6,95
ANCFA02	19,85	19,14	19,75	19,70	19,66	19,61	19,56	19,51	19,46	19,41	19,36	19,31
ANCFA13	0,99	0,96	0,99	0,99	0,98	0,98	0,98	0,98	0,97	0,97	0,97	0,97
ANCFA22	14,89	14,36	14,82	14,78	14,74	14,70	14,67	14,63	14,59	14,56	14,52	14,49

Tabla D 35. Producción total de los pozos con SLA HL 2017 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0420	7,22	6,97	7,19	7,17	7,15	7,13	7,12	7,10	7,08	7,06	7,05	7,03
ANC0424	7,22	6,97	7,19	7,17	7,15	7,13	7,12	7,10	7,08	7,06	7,05	7,03
ANC0434	7,22	6,97	7,19	7,17	7,15	7,13	7,12	7,10	7,08	7,06	7,05	7,03
ANC0582	3,61	3,48	3,59	3,59	3,58	3,57	3,56	3,55	3,54	3,53	3,52	3,51
ANC0667	6,94	6,69	6,90	6,88	6,87	6,85	6,83	6,82	6,80	6,78	6,76	6,75
ANC1073	21,67	20,90	21,57	21,51	21,46	21,40	21,35	21,30	21,24	21,19	21,14	21,08
ANC1393	4,82	4,64	4,79	4,78	4,77	4,76	4,74	4,73	4,72	4,71	4,70	4,69
ANC1395	1,93	1,86	1,92	1,91	1,91	1,90	1,90	1,89	1,89	1,88	1,88	1,87
ANC1396	3,85	3,72	3,83	3,82	3,81	3,81	3,80	3,79	3,78	3,77	3,76	3,75
ANC1703	9,63	9,29	9,58	9,56	9,54	9,51	9,49	9,47	9,44	9,42	9,39	9,37
ANC1713	6,94	6,69	6,90	6,88	6,87	6,85	6,83	6,82	6,80	6,78	6,76	6,75
ANCFA02	19,27	18,58	19,17	19,12	19,07	19,03	18,98	18,93	18,88	18,84	18,79	18,74
ANCFA13	0,96	0,93	0,96	0,96	0,95	0,95	0,95	0,95	0,94	0,94	0,94	0,94
ANCFA22	14,45	13,93	14,38	14,34	14,31	14,27	14,23	14,20	14,16	14,13	14,09	14,06

Tabla D 36. Producción total de los pozos con SLA HL 2018 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0420	7,01	6,76	6,98	6,96	6,94	6,92	6,91	6,89	6,87	6,85	6,84	6,82
ANC0424	7,01	6,76	6,98	6,96	6,94	6,92	6,91	6,89	6,87	6,85	6,84	6,82
ANC0434	7,01	6,76	6,98	6,96	6,94	6,92	6,91	6,89	6,87	6,85	6,84	6,82
ANC0582	3,51	3,38	3,49	3,48	3,47	3,46	3,45	3,44	3,44	3,43	3,42	3,41
ANC0667	6,73	6,49	6,70	6,68	6,66	6,65	6,63	6,61	6,60	6,58	6,56	6,55
ANC1073	21,03	20,28	20,93	20,87	20,82	20,77	20,72	20,67	20,62	20,56	20,51	20,46
ANC1393	4,67	4,51	4,65	4,64	4,63	4,62	4,60	4,59	4,58	4,57	4,56	4,55
ANC1395	1,87	1,80	1,86	1,86	1,85	1,85	1,84	1,84	1,83	1,83	1,82	1,82
ANC1396	3,74	3,61	3,72	3,71	3,70	3,69	3,68	3,67	3,66	3,66	3,65	3,64
ANC1703	9,35	9,01	9,30	9,28	9,25	9,23	9,21	9,19	9,16	9,14	9,12	9,09
ANC1713	6,73	6,49	6,70	6,68	6,66	6,65	6,63	6,61	6,60	6,58	6,56	6,55
ANCFA02	18,70	18,03	18,60	18,56	18,51	18,46	18,42	18,37	18,32	18,28	18,23	18,19
ANCFA13	0,93	0,90	0,93	0,93	0,93	0,92	0,92	0,92	0,92	0,91	0,91	0,91
ANCFA22	14,02	13,52	13,95	13,92	13,88	13,85	13,81	13,78	13,74	13,71	13,67	13,64

Tabla D 37. Producción total de los pozos con SLA HL 2019 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0420	6,80	6,79	6,54	6,75	6,74	6,72	6,70	6,69	6,67	6,65	6,64	6,62
ANC0424	6,80	6,79	6,54	6,75	6,74	6,72	6,70	6,69	6,67	6,65	6,64	6,62
ANC0434	6,80	6,79	6,54	6,75	6,74	6,72	6,70	6,69	6,67	6,65	6,64	6,62
ANC0582	3,40	3,39	3,27	3,38	3,37	3,36	3,35	3,34	3,33	3,33	3,32	3,31
ANC0667	6,53	6,51	6,28	6,48	6,47	6,45	6,43	6,42	6,40	6,39	6,37	6,35
ANC1073	20,41	20,36	19,63	20,26	20,21	20,16	20,11	20,06	20,01	19,96	19,91	19,86
ANC1393	4,54	4,52	4,36	4,50	4,49	4,48	4,47	4,46	4,45	4,43	4,42	4,41
ANC1395	1,81	1,81	1,74	1,80	1,80	1,79	1,79	1,78	1,78	1,77	1,77	1,76
ANC1396	3,63	3,62	3,49	3,60	3,59	3,58	3,57	3,57	3,56	3,55	3,54	3,53
ANC1703	9,07	9,05	8,72	9,00	8,98	8,96	8,94	8,91	8,89	8,87	8,85	8,82
ANC1713	6,53	6,51	6,28	6,48	6,47	6,45	6,43	6,42	6,40	6,39	6,37	6,35
ANCFA02	18,14	18,10	17,45	18,01	17,96	17,92	17,87	17,83	17,78	17,74	17,69	17,65
ANCFA13	0,91	0,90	0,87	0,90	0,90	0,90	0,89	0,89	0,89	0,89	0,88	0,88
ANCFA22	13,61	13,57	13,09	13,50	13,47	13,44	13,40	13,37	13,34	13,30	13,27	13,24

Tabla D 38. Producción total de los pozos con SLA HL 2020 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0420	6,60	6,37	6,57	6,55	6,54	6,52	6,50	6,49	6,47	6,45	6,44	6,42
ANC0424	6,60	6,37	6,57	6,55	6,54	6,52	6,50	6,49	6,47	6,45	6,44	6,42
ANC0434	6,60	6,37	6,57	6,55	6,54	6,52	6,50	6,49	6,47	6,45	6,44	6,42
ANC0582	3,30	3,18	3,28	3,28	3,27	3,26	3,25	3,24	3,24	3,23	3,22	3,21
ANC0667	6,34	6,11	6,31	6,29	6,27	6,26	6,24	6,23	6,21	6,20	6,18	6,17
ANC1073	19,81	19,10	19,71	19,66	19,61	19,56	19,51	19,46	19,41	19,36	19,32	19,27
ANC1393	4,40	4,24	4,38	4,37	4,36	4,35	4,34	4,32	4,31	4,30	4,29	4,28
ANC1395	1,76	1,70	1,75	1,75	1,74	1,74	1,73	1,73	1,73	1,72	1,72	1,71
ANC1396	3,52	3,40	3,50	3,49	3,49	3,48	3,47	3,46	3,45	3,44	3,43	3,43
ANC1703	8,80	8,49	8,76	8,74	8,71	8,69	8,67	8,65	8,63	8,61	8,59	8,56
ANC1713	6,34	6,11	6,31	6,29	6,27	6,26	6,24	6,23	6,21	6,20	6,18	6,17
ANCFA02	17,61	16,98	17,52	17,47	17,43	17,39	17,34	17,30	17,26	17,21	17,17	17,13
ANCFA13	0,88	0,85	0,88	0,87	0,87	0,87	0,87	0,86	0,86	0,86	0,86	0,86
ANCFA22	13,20	12,73	13,14	13,11	13,07	13,04	13,01	12,97	12,94	12,91	12,88	12,85

**Anexo E: Producción mensual de los pozos que operan con SW durante el periodo
2016-2020**

Tabla E 39. Producción total de los pozos con SLA SW 2016 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0162	19,80	19,09	19,70	19,65	19,60	19,55	19,50	19,45	19,40	19,36	19,31	19,26
ANC0163	46,11	44,47	45,88	45,77	45,65	45,54	45,43	45,31	45,20	45,09	44,97	44,86
ANC0589	60,55	58,39	60,25	60,10	59,95	59,80	59,65	59,50	59,35	59,20	59,06	58,91
ANC0655	30,28	29,19	30,13	30,05	29,98	29,90	29,83	29,75	29,68	29,60	29,53	29,45
ANC1493	22,71	21,90	22,59	22,54	22,48	22,43	22,37	22,31	22,26	22,20	22,15	22,09
ANC1648	29,99	28,91	29,84	29,76	29,69	29,61	29,54	29,46	29,39	29,32	29,24	29,17
ANC1678	15,14	14,60	15,06	15,03	14,99	14,95	14,91	14,88	14,84	14,80	14,76	14,73
ANC3007	29,40	28,35	29,26	29,18	29,11	29,04	28,97	28,89	28,82	28,75	28,68	28,60

Tabla E 40. Producción total de los pozos con SLA SW 2017 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0162	19,21	18,52	19,11	19,07	19,02	18,97	18,92	18,88	18,83	18,78	18,74	18,69
ANC0163	44,75	43,15	44,53	44,41	44,30	44,19	44,08	43,97	43,86	43,75	43,64	43,53
ANC0589	58,76	56,66	58,47	58,32	58,18	58,03	57,89	57,74	57,60	57,45	57,31	57,17
ANC0655	29,38	28,33	29,23	29,16	29,09	29,02	28,94	28,87	28,80	28,73	28,65	28,58
ANC1493	22,04	21,25	21,93	21,87	21,82	21,76	21,71	21,65	21,60	21,54	21,49	21,44
ANC1648	29,10	28,06	28,95	28,88	28,81	28,74	28,66	28,59	28,52	28,45	28,38	28,31
ANC1678	14,69	14,17	14,62	14,58	14,54	14,51	14,47	14,44	14,40	14,36	14,33	14,29
ANC3007	28,53	27,51	28,39	28,32	28,25	28,18	28,11	28,04	27,97	27,90	27,83	27,76

Tabla E 41. Producción total de los pozos con SLA SW 2018 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0162	18,64	17,98	18,55	18,50	18,46	18,41	18,36	18,32	18,27	18,23	18,18	18,14
ANC0163	43,43	41,87	43,21	43,10	42,99	42,89	42,78	42,67	42,56	42,46	42,35	42,25
ANC0589	57,02	54,98	56,74	56,60	56,45	56,31	56,17	56,03	55,89	55,75	55,61	55,47
ANC0655	28,51	27,49	28,37	28,30	28,23	28,16	28,09	28,02	27,95	27,88	27,81	27,74
ANC1493	21,38	20,62	21,28	21,22	21,17	21,12	21,06	21,01	20,96	20,91	20,85	20,80
ANC1648	28,24	27,23	28,10	28,03	27,96	27,89	27,82	27,75	27,68	27,61	27,54	27,47
ANC1678	14,26	13,75	14,18	14,15	14,11	14,08	14,04	14,01	13,97	13,94	13,90	13,87
ANC3007	27,69	26,70	27,55	27,48	27,41	27,34	27,28	27,21	27,14	27,07	27,00	26,94

Tabla E 42. Producción total de los pozos con SLA SW 2019 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0162	18,09	18,05	17,40	17,96	17,91	17,87	17,82	17,78	17,73	17,69	17,64	17,60
ANC0163	42,14	42,03	40,53	41,82	41,72	41,62	41,51	41,41	41,30	41,20	41,10	41,00
ANC0589	55,34	55,20	53,22	54,92	54,78	54,65	54,51	54,37	54,24	54,10	53,97	53,83
ANC0655	27,67	27,60	26,61	27,46	27,39	27,32	27,26	27,19	27,12	27,05	26,98	26,92
ANC1493	20,75	20,70	19,96	20,60	20,54	20,49	20,44	20,39	20,34	20,29	20,24	20,19
ANC1648	27,40	27,33	26,36	27,20	27,13	27,06	26,99	26,93	26,86	26,79	26,72	26,66
ANC1678	13,83	13,80	13,31	13,73	13,70	13,66	13,63	13,59	13,56	13,53	13,49	13,46
ANC3007	26,87	26,80	25,84	26,67	26,60	26,54	26,47	26,40	26,34	26,27	26,21	26,14

Tabla E 43. Producción total de los pozos con SLA SW 2020 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0162	17,56	16,93	17,47	17,42	17,38	17,34	17,29	17,25	17,21	17,16	17,12	17,08
ANC0163	40,89	39,43	40,69	40,59	40,49	40,38	40,28	40,18	40,08	39,98	39,88	39,78
ANC0589	53,70	51,78	53,43	53,30	53,16	53,03	52,90	52,77	52,63	52,50	52,37	52,24
ANC0655	26,85	25,89	26,71	26,65	26,58	26,52	26,45	26,38	26,32	26,25	26,19	26,12
ANC1493	20,14	19,42	20,04	19,99	19,94	19,89	19,84	19,79	19,74	19,69	19,64	19,59
ANC1648	26,59	25,64	26,46	26,39	26,33	26,26	26,19	26,13	26,06	26,00	25,93	25,87
ANC1678	13,42	12,94	13,36	13,32	13,29	13,26	13,22	13,19	13,16	13,13	13,09	13,06
ANC3007	26,07	25,14	25,94	25,88	25,81	25,75	25,69	25,62	25,56	25,49	25,43	25,37

**Anexo F: Producción mensual de los pozos que operan con BM durante el periodo
2016-2020**

Tabla F 44. Producción total de los pozos con SLA BM 2016. (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0437	14,85	14,32	14,77	14,74	14,70	14,66	14,63	14,59	14,55	14,52	14,48	14,44
ANC0446	59,10	56,99	58,80	58,66	58,51	58,36	58,22	58,07	57,93	57,78	57,64	57,49
ANC0458	29,69	28,63	29,55	29,47	29,40	29,33	29,25	29,18	29,11	29,03	28,96	28,89
ANC0461	46,29	44,63	46,06	45,94	45,83	45,71	45,60	45,48	45,37	45,26	45,14	45,03
ANC0465	150,80	145,41	150,05	149,67	149,30	148,93	148,55	148,18	147,81	147,44	147,07	146,71
ANC0504	124,60	120,15	123,98	123,67	123,36	123,05	122,74	122,44	122,13	121,82	121,52	121,22
ANC0508	31,44	30,32	31,28	31,21	31,13	31,05	30,97	30,90	30,82	30,74	30,66	30,59
ANC0585	101,60	97,97	101,09	100,84	100,59	100,34	100,09	99,84	99,59	99,34	99,09	98,84
ANC0656	31,15	30,04	30,99	30,92	30,84	30,76	30,69	30,61	30,53	30,46	30,38	30,30
ANC0778	81,22	78,32	80,82	80,62	80,41	80,21	80,01	79,81	79,61	79,41	79,22	79,02

Tabla F 45. Producción total de los pozos con SLA BM 2017. (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0437	14,41	13,89	14,34	14,30	14,26	14,23	14,19	14,16	14,12	14,09	14,05	14,02
ANC0446	57,35	55,30	57,06	56,92	56,78	56,64	56,49	56,35	56,21	56,07	55,93	55,79
ANC0458	28,82	27,79	28,67	28,60	28,53	28,46	28,39	28,32	28,24	28,17	28,10	28,03
ANC0461	44,92	43,31	44,69	44,58	44,47	44,36	44,25	44,14	44,03	43,92	43,81	43,70
ANC0465	146,34	141,11	145,61	145,24	144,88	144,52	144,16	143,80	143,44	143,08	142,72	142,36
ANC0504	120,91	116,59	120,31	120,01	119,71	119,41	119,11	118,81	118,52	118,22	117,92	117,63
ANC0508	30,51	29,42	30,36	30,28	30,21	30,13	30,06	29,98	29,91	29,83	29,76	29,68
ANC0585	98,60	95,07	98,10	97,86	97,61	97,37	97,13	96,88	96,64	96,40	96,16	95,92
ANC0656	30,23	29,15	30,08	30,00	29,93	29,85	29,78	29,70	29,63	29,55	29,48	29,41
ANC0778	78,82	76,00	78,43	78,23	78,03	77,84	77,64	77,45	77,26	77,06	76,87	76,68

Tabla F 46. Producción total de los pozos con SLA BM 2018. (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0437	13,98	13,48	13,91	13,88	13,84	13,81	13,77	13,74	13,70	13,67	13,64	13,60
ANC0446	55,65	53,66	55,37	55,24	55,10	54,96	54,82	54,69	54,55	54,41	54,28	54,14
ANC0458	27,96	26,96	27,82	27,75	27,68	27,62	27,55	27,48	27,41	27,34	27,27	27,20
ANC0461	43,59	42,03	43,37	43,26	43,16	43,05	42,94	42,83	42,73	42,62	42,51	42,41
ANC0465	142,01	136,93	141,30	140,95	140,59	140,24	139,89	139,54	139,19	138,85	138,50	138,15
ANC0504	117,34	113,14	116,75	116,46	116,17	115,88	115,59	115,30	115,01	114,72	114,43	114,15
ANC0508	29,61	28,55	29,46	29,39	29,31	29,24	29,17	29,09	29,02	28,95	28,88	28,80
ANC0585	95,68	92,26	95,20	94,96	94,72	94,49	94,25	94,02	93,78	93,55	93,31	93,08
ANC0656	29,33	28,29	29,19	29,11	29,04	28,97	28,90	28,82	28,75	28,68	28,61	28,54
ANC0778	76,49	73,75	76,11	75,92	75,73	75,54	75,35	75,16	74,97	74,78	74,60	74,41

Tabla F 47. Producción total de los pozos con SLA BM 2019 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0437	13,57	13,53	13,05	13,47	13,43	13,40	13,37	13,33	13,30	13,27	13,23	13,20
ANC0446	54,01	53,87	51,94	53,60	53,47	53,33	53,20	53,07	52,93	52,80	52,67	52,54
ANC0458	27,14	27,07	26,10	26,93	26,87	26,80	26,73	26,66	26,60	26,53	26,46	26,40
ANC0461	42,30	42,19	40,69	41,98	41,88	41,77	41,67	41,57	41,46	41,36	41,25	41,15
ANC0465	137,81	137,46	132,55	136,78	136,43	136,09	135,75	135,41	135,07	134,74	134,40	134,06
ANC0504	113,86	113,58	109,52	113,01	112,73	112,45	112,17	111,89	111,61	111,33	111,05	110,77
ANC0508	28,73	28,66	27,64	28,52	28,45	28,37	28,30	28,23	28,16	28,09	28,02	27,95
ANC0585	92,85	92,61	89,30	92,15	91,92	91,69	91,46	91,23	91,01	90,78	90,55	90,33
ANC0656	28,47	28,39	27,38	28,25	28,18	28,11	28,04	27,97	27,90	27,83	27,76	27,69
ANC0778	74,22	74,04	71,39	73,67	73,48	73,30	73,12	72,93	72,75	72,57	72,39	72,21

Tabla F 48. Producción total de los pozos con SLA BM 2020 (Pacifpetrol, 2021)

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
ANC0437	13,17	12,70	13,10	13,07	13,04	13,00	12,97	12,94	12,91	12,87	12,84	12,81
ANC0446	52,41	50,53	52,15	52,02	51,89	51,76	51,63	51,50	51,37	51,24	51,11	50,98
ANC0458	26,33	25,39	26,20	26,14	26,07	26,01	25,94	25,88	25,81	25,75	25,68	25,62
ANC0461	41,05	39,58	40,84	40,74	40,64	40,54	40,44	40,34	40,23	40,13	40,03	39,93
ANC0465	133,73	128,95	133,06	132,73	132,40	132,07	131,74	131,41	131,08	130,75	130,42	130,10
ANC0504	110,49	106,54	109,94	109,67	109,39	109,12	108,85	108,57	108,30	108,03	107,76	107,49
ANC0508	27,88	26,88	27,74	27,67	27,60	27,53	27,47	27,40	27,33	27,26	27,19	27,12
ANC0585	90,10	86,88	89,65	89,43	89,20	88,98	88,76	88,53	88,31	88,09	87,87	87,65
ANC0656	27,62	26,64	27,49	27,42	27,35	27,28	27,21	27,14	27,08	27,01	26,94	26,87
ANC0778	72,03	69,45	71,67	71,49	71,31	71,13	70,95	70,78	70,60	70,42	70,25	70,07

Anexo G: Producción anual en función del SLA

Tabla G 49. Producción acumulada anual (Pacifpetrol, 2021)

SLA	PRODUCCIÓN				
	2016	2017	2018	2019	2020
HL	1407,71	1366,05	1325,63	1286,41	1248,34
BM	7916,90	7682,63	7455,30	7234,74	7020,61
SW	2997,70	2909,00	2822,92	2739,40	2658,32

Anexo H: Algoritmo árbol de decisión

```
import pandas as pd
import numpy as np
import seaborn as sns
import graphviz
import matplotlib.pyplot as plt
import matplotlib.image as pltimg
import pydotplus
from sklearn import tree
from sklearn import metrics
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import accuracy_score, r2_score
from sklearn.metrics import classification_report
from sklearn.metrics import confusion_matrix
from sklearn.tree import export_graphviz
from sklearn.model_selection import cross_val_score
from sklearn.preprocessing import LabelEncoder
from IPython.display import Image
import plotly.express as px
```



```

TESIS_UPSE= pd.read_excel("info_pozosDT.xlsx")
TESIS_UPSE

TESIS_UPSE.columns=("Nombre_pozo","Profundidad","fm_productora","Reserva_fm
","Gravedad_API","Temperatura","Salinidad","Ciclos","Producción_acumulada","Gast
o_combustible","Gasto_grasas","Gasto_mant","N_intervenciones","cambios_sla_en_5_
años","Gasto_total","SLA")
TESIS_UPSE.columns

TESIS_UPSE.info()

TESIS_UPSE.describe()

TESIS_UPSE.groupby("SLA").SLA.count()
Contar_1= TESIS_UPSE['fm_productora'].value_counts()
Contar_2=TESIS_UPSE['N_intervenciones'].value_counts()
Contar_3= TESIS_UPSE['cambios_sla_en_5_años'].value_counts()

print("Cantidad de datos respecto a la formación productora:")
Contar_1

print("Cantidad de datos respecto al número de intervenciones realizadas a los pozos:")
Contar_2

print("Cantidad de datos respecto al cambio de SLA en el periodo 2016-2020:")
Contar_3

EST_UPSE= TESIS_UPSE
fig = px.bar(EST_UPSE, x="Nombre_pozo", y="Producción_acumulada",
color="SLA", barmode="group")
print("PRODUCCION ACUMULADA EN EL PERIODO 2016-2020 DE LOS POZOS
PRODUCTIVOS DE LA SECCION 66 DEL CAMPO GVV:")
fig.show()

```

```

EST_UPSE1 = TESIS_UPSE
fig = px.bar(EST_UPSE1, x="Nombre_pozo", y="Gasto_total", color="SLA",
barmode="group")
print("GASTOS TOTALES GENERADOS EN EL PERIODO 2016-2020 DE LOS
POZOS PRODUCTIVOS DE LA SECCION 66 DEL CAMPO GVV:")
fig.show()

EST_UPSE2 = TESIS_UPSE
fig = px.bar(EST_UPSE2, x="SLA", y="Producción_acumulada",
color="fm_productora", barmode="group")
print("BARRILES DE PETROLEO PRODUCIDOS EN EL PERIODO 2016- 2020 DE
LAS FORMACIONES PRODUCTORAS DE LA SECCION 66 DEL CAMPO GVV:")

fig.show(

EST_UPSE6 = TESIS_UPSE
fig = px.sunburst(EST_UPSE6, path=['SLA', 'Nombre_pozo'], values='Gravedad_API',
color='Gravedad_API')
fig.show()

TESIS_UPSE.corr()
correlation_mat = TESIS_UPSE.corr()

sns.heatmap(correlation_mat, annot = True)

plt.xlabel("Datos de los pozos de la seccion 66 del campo GGV")

plt.show()
TESIS_UPSE = TESIS_UPSE.drop('fm_productora',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Nombre_pozo',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Gasto_combustible',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Gasto_grasas',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Gasto_mant',axis=1)

```

```

TESIS_UPSE = TESIS_UPSE.drop('cambios_sla_en_5_años',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Profundidad',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Salinidad',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Temperatura',axis=1)
print(TESIS_UPSE.head())

TESIS_UPSE.count(0)/TESIS_UPSE.shape[0]*100

predictors=TESIS_UPSE[['Reserva_fm','Gravedad_API',
'Ciclos','Producción_acumulada','N_intervenciones', 'Gasto_total' ]]
target=TESIS_UPSE.SLA
predictors

preditors_labels=['Reserva_fm','Gravedad_API',
'Ciclos','Producción_acumulada','N_intervenciones', 'Gasto_total']
target_labels=['BM','HL','SW']
preditors_labels

target_labels

x_train,x_test,y_train,y_test=train_test_split(predictors,target,test_size=0.15,random_state=42)

arbol=DecisionTreeClassifier(max_depth=5)
arbol.fit(x_train,y_train)

y_pred=arbol.predict(x_test)
y_pred

print("precisión del arbol:", metrics.accuracy_score(y_test,y_pred))

cm=confusion_matrix(y_test,y_pred)
cm

```

```

export_graphviz(arbol,
                out_file='ARBOL_UPSE_RESULT.txt',
                class_names=target_labels,
                feature_names=preditores_labels,
                filled=True)
Image("ARBOL_UPSE_RESULT.jpeg" , width=1000, unconfined=True)

TESIS_UPSE = TESIS_UPSE.drop('Ciclos',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('N_intervenciones',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Gravedad_API',axis=1)
TESIS_UPSE = TESIS_UPSE.drop('Reserva_fm',axis=1)
print(TESIS_UPSE.head())

predictors1=TESIS_UPSE[['Producción_acumulada', 'Gasto_total' ]]
target1=TESIS_UPSE.SLA

preditores_labels1=['Producción_acumulada', 'Gasto_total']
target_labels1=['BM','HL','SW']

x_train,x_test,y_train,y_test=train_test_split(predictors1,target1,test_size=0.15,random_
state=42)
arbol1=DecisionTreeClassifier(max_depth=2)
arbol1.fit(x_train,y_train)

y_pred1=arbol1.predict(x_test)
y_pred1

arbol1.score(x_train,y_train)
export_graphviz(arbol1,
                out_file='ARBOL_UPSE_COMPROBAR.txt',
                class_names=target_labels1,
                feature_names=preditores_labels1,
                filled=True)
Image("ARBOL_UPSE_COMPROBAR.jpeg" , width=1000, unconfined=True)

```