

MODELO PREDICTIVO DE PRODUCCIÓN INCREMENTAL BASADO EN
REDES NEURONALES Y SERIES DE TIEMPO, PARA RECOBRO
SECUNDARIO POR INYECCIÓN DE AGUA EN UN CAMPO ESTUDIO DE
ECOPETROL

IVÁN EDUARDO ACOSTA CASTAÑEDA

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO QUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
MAESTRÍA EN INGENIERÍA DE PETRÓLEOS Y GAS
BUCARAMANGA
2018

MODELO PREDICTIVO DE PRODUCCIÓN INCREMENTAL BASADO EN
REDES NEURONALES Y SERIES DE TIEMPO, PARA RECOBRO
SECUNDARIO POR INYECCIÓN DE AGUA EN UN CAMPO ESTUDIO DE
ECOPETROL

IVÁN EDUARDO ACOSTA CASTAÑEDA

TRABAJO DE GRADO PARA OBTENER EL TÍTULO DE MAGISTER DE
PETROLEOS Y GAS

DIRECTOR

FABIAN OMAR BETANCOURT
MAGISTER EN INGENIERÍA

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
MAESTRÍA EN INGENIERÍA DE PETRÓLEOS Y GAS
BUCARAMANGA
2018

AGRADECIMIENTOS

A Dios por sus ilimitadas bendiciones y alegrías, a cada persona que hace parte de mi vida diaria, a mis compañeros y jefes por su apoyo incondicional en este proceso; y a la Universidad Industrial de Santander por darnos esta formación y oportunidad de ser mejores profesionales para aportar a esta maravillosa industria

DEDICATORIA

De manera especial y amorosa a mis pequeños Isabella y Manolo por quienes cada esfuerzo y sacrificio vale la pena, a mi amada esposa Tatiana que construye cada día una vida maravillosa para mí. A mis padres y hermano que me dieron las bases y fundamentos para seguir creciendo y aprendiendo y formando como persona y profesional.

TABLA DE CONTENIDO

INTRODUCCION	13
1 REDES NEURONALES	15
1.1 CONCEPTO GENERAL DE REDES NEURONALES.....	16
1.2 MECÁNICA DE LA OPERACIÓN DE LAS REDES NEURONALES.....	17
1.3 MECÁNICA DE LA OPTIMIZACIÓN	19
1.4 APLICACIONES EN LA INDUSTRIA DE PETRÓLEO Y GAS.....	19
2 ESCENARIOS DE DESARROLLO BASE.....	21
2.1 ESCENARIOS DE SUBSUELO	21
2.1.1 Desarrollo primario.....	21
2.1.2 Desarrollo Secundario.....	22
2.1.3 Perfiles Desarrollo Secundario.....	24
2.2 ESCENARIOS DE SUPERFICIE	24
3 MODELO PREDICTIVO PRODUCCIÓN INCREMENTAL.....	26
3.1 PERFILES PRODUCCIÓN INCREMENTAL.....	26
4 MODELO ANALÍTICO INTEGRADO	32
4.1 ESCENARIOS DE DESARROLLO	32
4.1.1 Modelo Técnico Económico.....	32
4.1.2 Premisas Financieras	34
4.1.3 Proyección precio BRENT series de tiempo	34
5 MODELO DE OPTIMIZACIÓN E INCERTIDUMBRE	38
5.1 EXPANSIÓN INYECCIÓN DE AGUA 2018:	39
5.2 EXPANSIÓN INYECCIÓN DE AGUA 2019:	41
5.3 EXPANSIÓN INYECCIÓN DE AGUA 2020:	43
CONCLUSIONES	46
RECOMENDACIONES.....	47
BIBLIOGRAFIA.....	48
ANEXOS.....	50

LISTA DE FIGURAS

Figura 1 Curva básica con efecto de mantenimiento de presión.	22
Figura 2. Pronóstico de producción y capacidad instalada campo estudio.	24
Figura 3 Perfiles de producción incremental total pozos afectados	26
Figura 4 Ajuste emulado versus real.....	28
Figura 5 Perfiles de producción incremental probabilístico por patrón.....	30
Figura 6 Histograma de acumulados incrementales por patron.....	30
Figura 7 Históricos precios BRENT 1961 – 2017.....	35
Figura 8 Modelos de ajuste precio BRENT	36
Figura 9 Zona de ajuste para últimos 10 años	36
Figura 10 Proyección de precios y valores medios para crudo BRENT.....	37
Figura 11 Iteraciones buscando maximizar el VPN	38
Figura 12 Perfiles Producción de petróleo expansión @ 2018	40
Figura 13 Histograma reservas y volúmenes técnicos @ 2018.....	40
Figura 14 VPN vs Reservas WF @ 2018.....	41
Figura 15 Perfiles Producción de petróleo expansión @ 2018	42
Figura 16 Histograma reservas y volúmenes técnicos @ 2019.....	42
Figura 17 VPN vs Reservas WF @ 2018.....	43
Figura 18 Perfiles Producción de petróleo expansión @ 2020	44
Figura 19 Histograma reservas y volúmenes técnicos @ 2020.....	44
Figura 20 VPN vs Reservas WF @ 2020.....	45
Figura 21 VPN vs Reservas @ 45 - 50 USD Volúmenes P50 y P90	47

LISTA DE TABLAS

Tabla 1 Actividades inicio expansión	23
Tabla 2 Error cuadrático ajustado	28
Tabla 3 Ajustes red neuronal por patron	29

LISTA DE ANEXOS

Anexo A. Variables empleadas en el modelo analítico.....	51
Anexo B. Flujo de trabajo.....	54

RESUMEN

TITULO: MODELO PREDICTIVO DE PRODUCCIÓN INCREMENTAL BASADO EN REDES NEURONALES Y SERIES DE TIEMPO, PARA RECOBRO SECUNDARIO POR INYECCIÓN DE AGUA EN UN CAMPO ESTUDIO DE ECOPETROL

AUTOR: IVAN EDUARDO ACOSTA CASTAÑEDA*

PALABRAS CLAVES: REDES NEURONALES, INYECCION DE AGUA, PRODUCCIÓN, RECOBRO.

La inyección de agua o recobro secundario empleado hoy en el campo estudio, es considerada después de varios análisis como una de las mejores formas de incrementar el recobro e incorporar reservas, luego de un desarrollo primario satisfactorio.

Pese a lo anterior, los modelos actuales empleados en la compañía para inferir el comportamiento incremental resultante de los procesos de inyección de agua propuestos, requieren de tiempos considerables para su evaluación, así como de modelos estáticos confiables y simulaciones ajustadas a requerimientos específicos, que resultan generalmente en una prognosis sin mayores sensibilidades o probabilísticas de el o los escenarios planteados. Todo esto aunado a tiempos cortos para la evaluación de proyectos, requisitos de toma de decisión confiables y pocos modelos completos de simulación Full Field, hacen necesario la incorporación de modelos y métodos que consideren incertidumbre, riesgo y predicción.

Debido a estos requerimientos y retos se llevó a cabo la elaboración de un modelo que permite la rápida predicción de perfiles incrementales asociados a patrones de inyección, mediante el uso de redes neuronales y predicción de precios basados en series de tiempo, para la toma de decisiones bajo riesgo e incertidumbre.

De esta forma, el presente trabajo, logra enmarcar los cambios en las premisas de valoración de los proyectos de la organización para el 2017 (precio de referencia BRENT, disminución de descuento de calidad entre otros), así como ajustes a los pronósticos incrementales para la inyección de agua debido al resultado de pilotos y algunas actualizaciones del modelo de simulación para el Campo Estudio, como también nuevas alternativas de facilidades de superficie.

* Trabajo de grado

** Facultad de Ingenierías Físicoquímicas. Escuela de Ingeniería de Petróleos. Director: M. Sc Fabian Omar Betancourt.

ABSTRACT

TITLE: PREDICTIVE MODEL OF INCREMENTAL PRODUCTION BASED ON NEURAL NETWORKS AND TIME SERIES, FOR SECONDARY RECOVERY BY WATER INJECTION IN A FIELD ECOPETROL STUDY

AUTHOR: IVAN EDUARDO ACOSTA CASTAÑEDA

KEY WORDS: NEURAL NETWORKS, WATER INJECTION, PRODUCTION, RECOVERY

The water flooding or secondary recovery process used in the study field today considered after different analyzes as one of the best methods to increase the recovery factor and incorporate additional reserves, after a satisfactory primary development.

However of the above conditions, the actual models used in the company to predict the incremental production resulting from the water flooding process, require considerable time to evaluated, as well as reliable static models and simulations adjusted to specific requirements, which result generally in a prognosis with minimal sensitivities or probabilities for the proposed scenarios. In other way, considering short evaluation time for the projects, reliable decision-making requirements and few full models for Full Field simulation, make it necessary to incorporate models and methods that consider uncertainty, risk and prediction.

Based on these requirements and challenges, a model was developed that allows the rapid prediction of incremental profiles associated with injection patterns, through the use of neural networks and price predictions based on time series, for decision making under risk and uncertainty.

INTRODUCCION

La visión de desarrollo para el campo estudio, documenta las evaluaciones de optimización realizadas sobre un escenario de actividad identificado por los grupos de subsuelo de la compañía y a partir del cual se construyeron y sensibilizaron escenarios alternativos de desarrollo implementando modelos de redes neuronales y series de tiempo, para identificar casos óptimos de desarrollo. El proceso de construcción se ha dividido en dos partes; una primera fase correspondiente al modelamiento de escenarios de la actividad asociada a recobro primario (determinístico), y una segunda fase en donde se llevó a cabo un modelamiento probabilístico para la visión de recobro secundario.

El campo estudio se encuentra localizado en el departamento del Meta, aproximadamente 30 Kms. al sur de Villavicencio, en jurisdicción de los municipios de Acacías, y Castilla La Nueva. Inició producción en 1985 y sus principales unidades productoras son las formaciones Guadalupe masivo, Guadalupe superior de edad Cretáceo Medio (unidades operacionales K1 y K2) y San Fernando (unidad T2).

De acuerdo con el comportamiento general de la producción primaria se puede afirmar que el principal mecanismo de producción ha sido para la unidad T2 la expansión de roca y fluidos, mientras que para las unidades K1 y K2 se cuenta con un acuífero activo.

El OOIP en la unidad T2 es de 2865 MBIs y en las unidades K1-K2 de 247 MBIs. Para el segundo trimestre de 2015 el campo tiene una producción acumulada de 137.1 MBIs de petróleo, 6.4 GSCF de gas y 228.6 MBIs de agua y cuenta con 204 pozos productores activos. El FR actual en la unidad K1-K2 es de 18% y en T2 de 3,07% La producción diaria es del orden de 67200 BOPD, 69800 BWPD y 4539 MSCFD de gas.

El desarrollo del campo a corto, mediano y largo plazo se plantea bajo un esquema primario que consiste en el mantenimiento de la producción básica; y un desarrollo secundario fundamentado en pilotos a escala con el objetivo de incrementar el conocimiento de las metodologías a aplicar y su efecto sobre el yacimiento, a fin de facilitar su expansión a escala comercial de acuerdo con los resultados obtenidos. Los cuales hasta el presente, confirman la necesidad de proseguir con la expansión urgente de la inyección de agua en aras de asegurar los volúmenes técnicos, sin embargo es relevante mitigar los riesgos implícitos en esta estrategia incluyendo el análisis de las eficiencias áreal y vertical observadas en los pilotos y definir e implementar los planes de mejora tanto operativos como de caracterización para aumentar la probabilidad de éxito del proyecto pues a precios cercanos a 45 dólares la rentabilidad se ve impactada significativamente.

1 REDES NEURONALES

Los modelos de redes neuronales se remontan a principios de los años 60 y han venido históricamente siendo aplicados a distintas industrias, disciplinas y mercados, pasando por análisis carácter científico, salud, social, financiero entre muchos otros; sin embargo en la industria del petróleo da sus primeros pasos hacia los años 80, con una mayor aplicación en la década de los 90 y llegando a una madurez significativa durante la última década, esto gracias al surgimiento de nuevas herramientas de análisis que facilitan la solución de problemas que antes eran difíciles o casi imposibles de resolver, aunado a las capacidades computacionales modernas y la necesidad de tomar decisiones con sentidos más lógicos que personales.

Teniendo en cuenta que las redes neuronales han mostrado ser una opción relevante en la solución de problemas donde es necesario correlacionar parámetros, la industria de los hidrocarburos las ha utilizado en diferentes áreas. En 1991 McCormack, presentó una hipótesis relevante de la importancia y aplicabilidad que podrían darle a la industria los sistemas de redes neuronales¹. Posteriormente Ali, J. K en 1994, lleva a cabo un análisis de la versatilidad y distintas disciplinas y la relevancia para el sector petrolero en los que se llevarían a cabo aplicaciones de las redes neuronales, con métodos tradicionales². Un año después, Kumoluyi, considero relevante adicionar al sistema de lógica difusa una complementariedad con modelos de estadística y probabilidad clásica³.

A partir de ese momento cientos de autores y académicos vienen profundizando en la utilización de estos sistemas prácticamente en todos los campos de la

¹ McCormack, M. P. (1991, January 1). Neural Networks In the Petroleum Industry. Society of Exploration Geophysicists.

² Ali, J. K. (1994, January 1). Neural Networks: A New Tool for the Petroleum Industry? Society of Petroleum Engineers. doi:10.2118/27561-MS

³ Kumoluyi, A. O. (1995, January 1). Higher-Order Neural Networks in Petroleum Engineering. Society of Petroleum Engineers. doi:10.2118/27905-MS

cadena de valor para la industria petrolera, desde caracterización del yacimiento, extrapolación de registros eléctricos, laborando algoritmos para analizar los registros eléctricos de pozos, optimizar modelos de perforación, predecir fallas de equipos, proyección de precios de venta y comercialización de petróleo, diseños de fracturas entre muchas otras aplicaciones.

La tendencia ahora parece ser la integración de estas herramientas en conjunto, con sistemas avanzadas de análisis de datos, modelos estadísticos complejos y algoritmos de optimización de tipo lineal, matricial y /u ortogonales, llevándonos así a la construcción cada día de modelos complejos y de mayor precisión.

1.1 CONCEPTO GENERAL DE REDES NEURONALES

Las redes neuronales artificiales, la lógica difusa y la programación evolutiva hacen parte de los modelos catalogados como inteligencia artificial o de aprendizaje computacional y pueden definirse como un conjunto de herramientas y algoritmos que tratan de recrear la vida tal y como la como los seres humanos la percibimos incluyendo la capacidad de aprender y recrear situaciones sobre las cuales hallar solución. Esto mediante principios de generalización, agrupación, descubrimiento y abstracción.

Una red neuronal artificial basa su fundamento de forma similar al sistema de procesamiento que usa una red neuronal biológica, entendiendo que este sistema hace parte de todos los organismos vivos cuyo elemento básico pero principal de sus sistemas nerviosos son las células, llamadas neuronas⁴.

Una neurona típica contiene un cuerpo celular donde se encuentra el núcleo, unas dendritas y un axón. La información entra en el cuerpo celular de las dendritas en forma de un tren de impulsos electro-químicos (señales). Dependiendo de la naturaleza de esta entrada la neurona se activa en una forma

⁴ Tomado de Wikipedia (http.es.wikipedia.org/wiki/red_neuronal)

de excitación o inhibición y ofrece una respuesta que viaja a través del axón y se conecta con otras neuronas a través de lo que se convierte en la entrada a la neurona receptora. El momento cuando la terminación del axón de una neurona entra en estrecha proximidad con las dendritas o el cuerpo celular de otra, se llama sinapsis. Las señales que viajan desde la primera neurona inician un tren de impulsos electro-químicos (señales) en la segunda neurona⁵.

Ahora bien, si de esta forma funciona un sistema neuronal natural, lo que concierne a un sistema de redes neuronales artificiales no es más que una imitación aproximada y simplificada de este proceso biológico. Para ello su principio es la estandarización de los modelos matemáticos de la cognición humana o de la biología neural, enmarcados con los siguientes principios:

El procesamiento de la información se produce en muchos elementos simples que se llaman neuronas (elementos de procesamiento). Las señales se transmiten entre las neuronas a través de enlaces de conexión. Cada conexión tiene asociado un vínculo de peso, que en una red neuronal típica, multiplica la señal que se transmite. Cada neurona aplica una función de activación (por lo general no lineal) a su red de entrada para determinar su señal de salida.

1.2 MECÁNICA DE LA OPERACIÓN DE LAS REDES NEURONALES

Una red neuronal artificial es un conjunto de neuronas que se organizan en formaciones específicas. Las neuronas se agrupan en capas. En una red multicapa hay por lo general, una capa de entrada, una o más capas ocultas y una capa de salida. El número de neuronas en la capa de entrada se corresponde con el número de parámetros que se presentan a la red como entrada. Lo mismo es cierto para la capa de salida. Cabe señalar que el análisis de redes neuronales no se limita a una sola salida, y que las redes neuronales pueden ser entrenadas para construir neuro - modelos con múltiples salidas. Las neuronas en la capa o capas ocultas son principalmente responsables de la

⁵ www.lacomunidadpetrolera.com/2008/redesneuronalesartificiales

característica de extracción. Proporcionan una mayor dimensión y acomodan tareas como la clasificación y el reconocimiento de patrones.

Hay muchos tipos de redes neuronales. Una de las clasificaciones más populares se basa en los métodos de entrenamiento. Las redes neuronales se pueden dividir en dos grandes categorías sobre la base de los métodos de entrenamiento, supervisadas y no supervisadas. Las no supervisadas, son principalmente las agrupaciones y los algoritmos de clasificación. Se han empleado en la industria de petróleo y gas para interpretar registros de pozos y determinar litología. Se les llama no supervisadas simplemente porque no se proporciona retroalimentación a la red. La red es llamada a clasificar los vectores de entrada en grupos y categorías.

Esto requiere un cierto grado de redundancia en la entrada de datos y, por tanto, se tiene la noción de que esa redundancia es conocida. La mayoría de las aplicaciones de redes neuronales en la industria de petróleo y gas se basan en algoritmos de entrenamiento supervisado. Durante un proceso de entrenamiento supervisado la entrada y la salida de información son presentadas a la red para permitir el aprendizaje en base a la retroalimentación. Se seleccionan la topología y el algoritmo de entrenamiento, luego la red neuronal es entrenada hasta que converge. Durante el proceso de entrenamiento de redes neuronales se trata de converger a una representación interna del comportamiento del sistema⁶.

En un típico procedimiento neuronal de procesamiento de datos, la base de datos se divide en tres partes llamadas entrenamiento, calibración y verificación de conjuntos. El conjunto de entrenamiento se utiliza para desarrollar la red deseada. En este proceso, el resultado deseado en el entrenamiento se utiliza para ayudar a la red a ajustar los pesos entre las neuronas o de sus elementos

⁶ Alonso, Guillermo; Becerril, José Luis. Introducción a la inteligencia artificial Técnicas y programas. Editorial: Multimedia Ediciones, 1993

de procesamiento. Durante el proceso de entrenamiento se plantea la cuestión de saber cuándo detener la formación. Ya que una red puede estar sobreentrenada. En la literatura sobre redes neuronales esto es conocido también como memorización. Una vez que la red memoriza un conjunto de datos, sería incapaz de la generalización.

1.3 MECÁNICA DE LA OPTIMIZACIÓN

La generación de escenarios o alternativas optimizadas, se realiza mediante combinatoria y búsqueda tabú, partiendo de dos procesos iterativos anidados, que funcionan de la siguiente forma: el ciclo externo combina las decisiones para crear escenarios; según este vaya avanzando en iteraciones y al paso de cada iteración externa se activa el algoritmo estocástico con el ciclo de iteraciones internas para crear las realizaciones que definirán las incertidumbres de cada escenario.

El proceso iterativo logra durante la simulación, y a medida que recorre las diferentes combinaciones, maximizar algunos escenarios apuntando siempre a una función objetivo preestablecida, descartando a medida que avanza, aquellas que destruyen valor o no cumplen con esta función y concentrándose en aquellas que impactan positivamente.

1.4 APLICACIONES EN LA INDUSTRIA DE PETRÓLEO Y GAS

Las Redes Neuronales se han utilizado para predecir o medir virtualmente las características de la formación tales como porosidad, permeabilidad y saturación de fluido a partir de registros convencionales de pozos. También consta en la literatura que las Redes Neuronales tienen el potencial de ser utilizado como un instrumento de análisis para la generación de imágenes de resonancia magnética sintéticas a partir de los registros de pozos convencionales. Hay muchas más aplicaciones de las Redes Neuronales en la industria de petróleo y gas. Incluyen aplicaciones al desarrollo de campos, flujo bifásico en tuberías, la

identificación de modelos en la interpretación de pruebas de pozos, análisis de terminaciones, la predicción del daño de formación, predicción de la permeabilidad, y en yacimientos fracturados⁷.

Es de suma importancia resaltar, que si el problema en evaluación es posible de resolverse de forma tradicional o con métodos convencionales, la utilización de redes neuronales podría no generar un mayor valor o resultado significativamente distinto. Tomando relevancia su implementación en aquellos casos donde los modelos matemáticos son imprácticos o en los casos donde las variables que intervienen en un proceso son muy inciertas o con incertidumbres significativas cuya interdependencia dificulten el modelado tradicional.

⁷ Tomado de www.oilproduction.net

2 ESCENARIOS DE DESARROLLO BASE

En este capítulo se presenta una descripción del caso base de desarrollo en términos de producción para el campo estudio, así como alternativas de facilidades, premisas de perforación y demás componentes que se usaron como base para generar el modelo integrado.

2.1 ESCENARIOS DE SUBSUELO

Actualmente se tienen definidos 2 módulos de desarrollo a nivel de subsuelo para incrementar el factor de recobro en el campo, mediante proyectos de desarrollo primario el cual se mantendrá como caso fijo, y el proceso recuperación secundaria (expansión inyección de agua) sobre el cuál se hizo el análisis de redes para predicción y sensibilidad a los perfiles esperados.


2.1.1 Desarrollo primario. Mantenimiento de la producción básica: Principalmente enfocado en intervenciones a pozos y estimulaciones matriciales, esta se llevara a cabo en 20 pozos del campo y asegurará la curva básica de producción y aportar en unos volúmenes adicionales cercanos a 1.09 MBIs. Contempla también la perforación de 4 pozos contingentes, que se encuentran ubicados al sur del campo y cuya producción asociada es del orden de los 1.79 MBIs de aceite.

Por último y no menos relevante, el desarrollo primario considera la ejecución de 9 trabajos de intervención, para aislar agua en la zona norte del campo, cambios de sistema de levantamiento artificial y optimización de la presión de fondo, esperando aportar a esta fase cerca de 2.47 MBIs de aceite, En conclusión los volúmenes correspondientes a esta fase los cuales se mantendrán sin sensibilidad para este estudio serian cercanos a 5.2 MBIs.

Es importante resaltar que en este desarrollo primario hay un impacto asociado a la ejecución actual de varios pilotos a lo largo del campo, y un cierre esperado

a 2017 de 17 patrones de prueba, el modelo de simulación refleja un efecto de disminución en la tasa de declinación de la curva básica actual, el cual podría o no darse; sin embargo para efectos del ejercicio se evaluó el efecto de los dos casos para contemplar el espectro total. De esta forma la curva básica podría tener un impacto tal como se muestra en la Figura 1 y en conjunto con las intervenciones previamente mencionadas obtendría a un límite técnico volúmenes que oscilan entre los 108 y 123 MBIs.

Figura 1. Curva básica con efecto de mantenimiento de presión.



2.1.2 Desarrollo Secundario. Dadas las características petrofísicas de la unidad principal del campo, el comportamiento de los fluidos, el resultado exitoso de más de la mitad de 17 pilotos y la ausencia de mecanismos de soporte diferentes a la expansión de roca y fluidos, se planea implementar un proceso de recobro secundario por inyección de agua asociado a 42 patrones, aprovechando el agua sobrante de los procesos de extracción de las otras formaciones del campo y soportado en modelos de simulación numérica que se ha venido ajustando con el resultado de las pruebas en campo.

Es sobre estos resultados de simulación que se llevó a cabo el ajuste por redes neuronales y la extrapolación para el modelo probabilístico integrado; buscando

resolver incertidumbres asociadas al mejor caudal a inyectar, la mejor fecha de inicio del proyecto y las condiciones de mercado que serían más favorables para expandir la inyección.

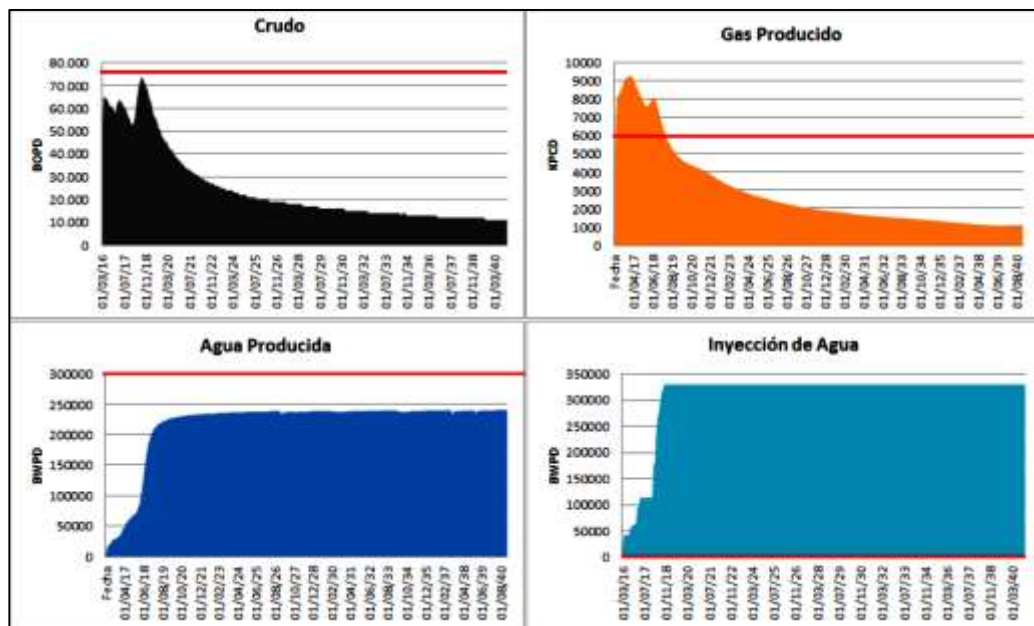
En resumen la actividad planteada para esta etapa incluye la perforación de 15 pozos y la conversión de 14, y se llevarían a cabo entre 2017 y 2019 como se ve en la Tabla 1

Tabla 1. Actividades inicio expansión

POZO INYECTOR	ACT	PERF	CONV	FECHA
100	Conv		1	2017
110	Conv		1	2019
117	Piloto			2017
119	Piloto			2017
130	Conv		1	2019
184	Perf	1		2019
185	Perf	1		2019
186	Perf	1		2019
187	Perf	1		2019
207	Piloto			2017
208	Piloto			2016
209	Piloto			2017
214	Perf	1		2019
215	Perf	1		2019
216	Perf	1		2019
217	Perf	1		2019
218	Perf	1		2019
219	Perf	1		2019
29	Piloto			2017
31	Conv		1	2019
52	Piloto			2014
59	Piloto			2017
60	Piloto			2017
68	Piloto			2015
90H	Conv		1	2019
99	Piloto			2017
6	Conv		1	2019
12	Conv		1	2019
13	Conv		1	2019
23	Piloto			2017
25	Conv		1	2019
28	Conv		1	2019
30	Piloto			2017
34	Conv		1	2019
40	Piloto			2017
44	Piloto			2017
46	Piloto			2017
49	Conv		1	2019
65	Conv		1	2019
72	Conv		1	2019
75	Piloto			2017
77	Perf	1		2019
78	Perf	1		2019
79	Perf	1		2019
80	Perf	1		2019

2.1.3 Perfiles Desarrollo Secundario. De acuerdo con el modelo de inyección de agua propuesto basado en 42 patrones con espaciamiento de 40 acres para el campo estudio, se muestran en las Figura 2 los perfiles determinísticos de producción de aceite, agua, gas e inyección de agua respectivamente.

Figura 2. Pronóstico de producción y capacidad instalada campo estudio.



2.2 ESCENARIOS DE SUPERFICIE

Para lo concerniente a las alternativas de superficie que se evaluaron en el modelo integrado, y partiendo de los perfiles de producción esperados, en los sistemas de tratamiento, separación, dilución y transporte en superficie, se consideró que para la curva básica de producción o escenario primario de desarrollo del campo no se requieren inversiones; sin embargo, de llevarse a cabo el proyecto de inyección de agua, o cualquier proceso de recobro mejorado, esta premisa se vería impactada considerablemente, asignando costos de capital para dichas alternativas que se incluyen en el modelo integrado.

Producto de estos perfiles esperados se generaron las siguientes alternativas a nivel de superficie:

Alternativa 1: Todo el fluido de recolección se trata en la Estación Principal. Y allí mismo se centralizan las bombas de inyección para abastecer mediante líneas de alta presión todo el campo.

Alternativa 2: Todo el fluido de recolección se trata en la Estación Principal. Y allí mismo se centralizan las bombas de inyección para abastecer mediante líneas de alta presión la zona norte y centro del campo. Se envía línea de baja presión desde la Estación Principal a la Estación de bombeo Sur y desde allí se abastece el resto del campo.

Alternativa 3: Todo el fluido de recolección se trata en la Estación Principal pero el sistema de inyección y bombeo se reparte equidistantemente a lo largo del activo con líneas de baja presión, re presurizando el sistema en cada zona del campo.

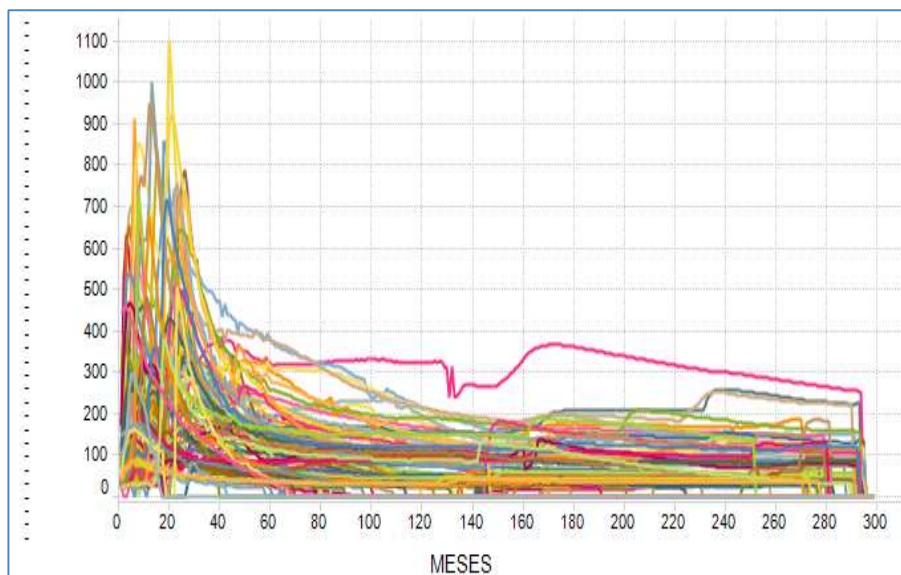
3 MODELO PREDICTIVO PRODUCCIÓN INCREMENTAL

En este capítulo se explica el procedimiento de entrenamiento, prueba y predicción del sistema de redes neuronales y los resultados obtenidos del mismo a partir de los resultados de simulación numérica para los 42 patrones de inyección propuestos.

3.1 PERFILES PRODUCCIÓN INCREMENTAL

Con el propósito de obtener un resultado probabilístico y predictivo de los volúmenes técnicos a desarrollar, la producción acumulada y los perfiles de petróleo, agua y gas incremental para los pozos existentes, se extrajo cada uno de los perfiles originales provenientes del modelo de simulación Figura 3, tratando de encontrar alguna tendencia o comportamiento tipo basado en tiempos de llenado, rampa o incremento, tiempo de plateau o mantenimiento de producción y declinación de los mismos. Sin embargo al observar los resultados de cada pozo afectado por la inyección era bastante difícil lograr dicha parametrización de forma manual y confirmando la necesidad de la red neuronal.

Figura 3. Perfiles de producción incremental total pozos afectados



Tomando como referencia cada una de las producciones asociadas a cada pozo productor afectado por la inyección, migramos estos datos a la herramienta NeuralTool de la empresa PALISADE, la cual trabaja con modelos multi capa de redes neuronales y que en la práctica funciona de la siguiente manera: cada neurona artificial se ocupa de varias funciones básicas. En primer lugar, se evalúan las señales de entrada y determina la fuerza de cada uno de ellos, luego se calcula un total de la combinación de las señales de entrada y compara ese total para algún nivel umbral. Por último, se determina lo que debería ser la respuesta mediante una función de activación o inicio. Inicialmente a cada entrada se le asigna un peso relativo al azar y a medida que se surte el proceso, el peso de las entradas es ajustado automáticamente para mejorar la fuerza de su conexión con la neurona de la capa siguiente. De esta manera, la respuesta de la red se compara con el resultado deseado o real que forma parte del conjunto de datos de entrenamiento, y la diferencia (error), se propaga hacia atrás a través de la red hasta lograr cada vez un mejor ajuste, proceso que se realiza de forma sistemática y puede ser detenido por tiempo limite, numero de pruebas o ajuste del error o residuales deseado. La red converge cuando su producción es aceptable dentro de la proximidad de la salida deseada y esta se aplica finalmente a los datos de verificación.

Durante el proceso de entrenamiento de nuestro caso particular, se lograron dos ajustes uno de tipo regresión lineal y otro por supervisión multicapa, tal como se observa en la Figura 4 y bajo los parámetros resumidos en las Tablas 2 y 3. (Datos de ajustes completos Anexos 1 y 2)

Figura 4. Ajuste emulado versus real

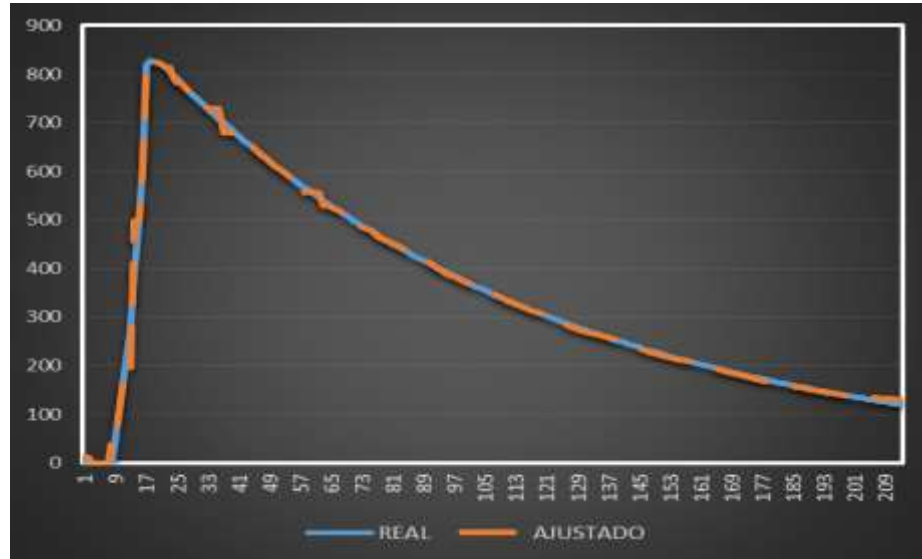


Tabla 2. Error cuadrático ajustado

Predicción lineal y red neuronal		
	Predicción lineal	Red neuronal
R-Cuadrado (Entrenamiento)	1,0000	-
Error cuadrático medio (Entrenamiento)	1,335	0,04891
Error cuadrático medio (Prueba)	1,172	2,189

Tabla 3. Ajustes red neuronal por patron

Función lineal	
	Intercep/Coeficiente
<i>Intercep</i>	0,8062
<i>P1OIL</i>	0,000
<i>P2OIL</i>	-0,000002038
<i>P3OIL</i>	0,000
<i>P4OIL</i>	-0,000008697
<i>P5OIL</i>	0,0000003712
<i>P6OIL</i>	17,01
<i>P7OIL</i>	-4,931
<i>P8OIL</i>	0,000
<i>P9OIL</i>	0,000
<i>P10OIL</i>	-17,76
<i>P11OIL</i>	0,000
<i>P12OIL</i>	-1,305
<i>P13OIL</i>	0,000
<i>P14OIL</i>	0,2164
<i>P15OIL</i>	0,000005398
<i>P16OIL</i>	0,000
<i>P17OIL</i>	-0,00003809
<i>P18OIL</i>	-8,857
<i>P19OIL</i>	0,000
<i>P20OIL</i>	-4,416
<i>P21OIL</i>	0,000
<i>P22OIL</i>	0,000
<i>P23OIL</i>	0,000
<i>P24OIL</i>	0,000
<i>P25OIL</i>	0,000
<i>P26OIL</i>	6,361
<i>P27OIL</i>	0,00004161
<i>P28OIL</i>	0,000
<i>P29OIL</i>	0,000
<i>P30OIL</i>	8,009
<i>P31OIL</i>	0,000
<i>P32OIL</i>	4,080
<i>P33OIL</i>	0,000
<i>P34OIL</i>	-0,2885
<i>P35OIL</i>	-0,00002629
<i>P36OIL</i>	0,000
<i>P37OIL</i>	0,000
<i>P38OIL</i>	-4,389
<i>P39OIL</i>	0,000
<i>P40OIL</i>	0,000
<i>P41OIL</i>	0,00001563

De esta manera, se logró generar un rango de posibilidades para los perfiles de producción incremental, migrando del caso base determinístico a un modelo de probabilidades y ocurrencia, pues de esta manera cada patrón podría comportarse dentro de un rango de posibilidades basado en los datos de simulación, y su volumen acumulado final también se movería en un espectro propio. Ver Figuras 5 y 6.

Figura 5 Perfiles de producción incremental probabilístico por patrón

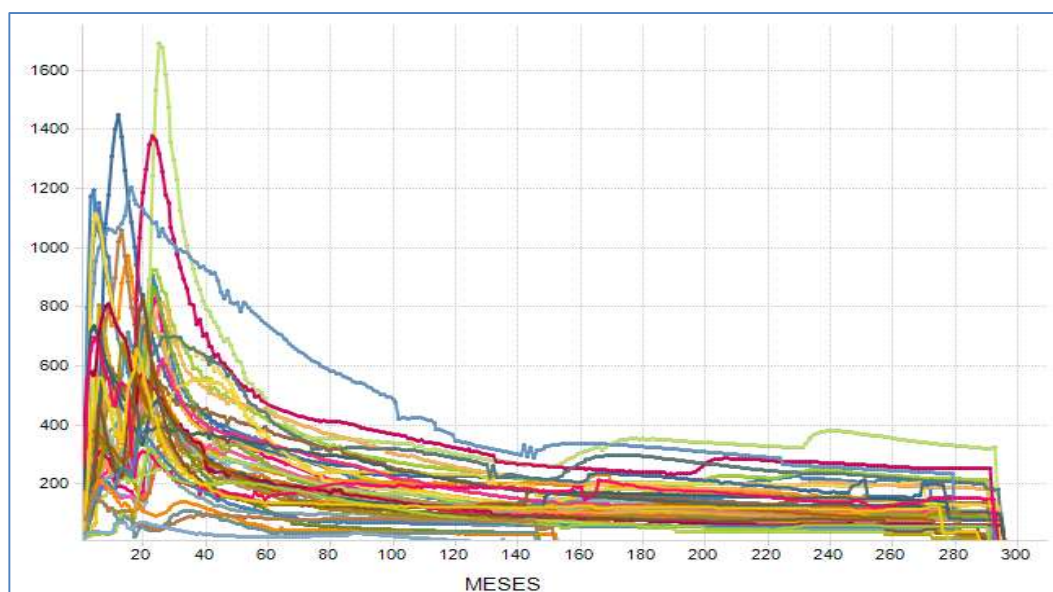
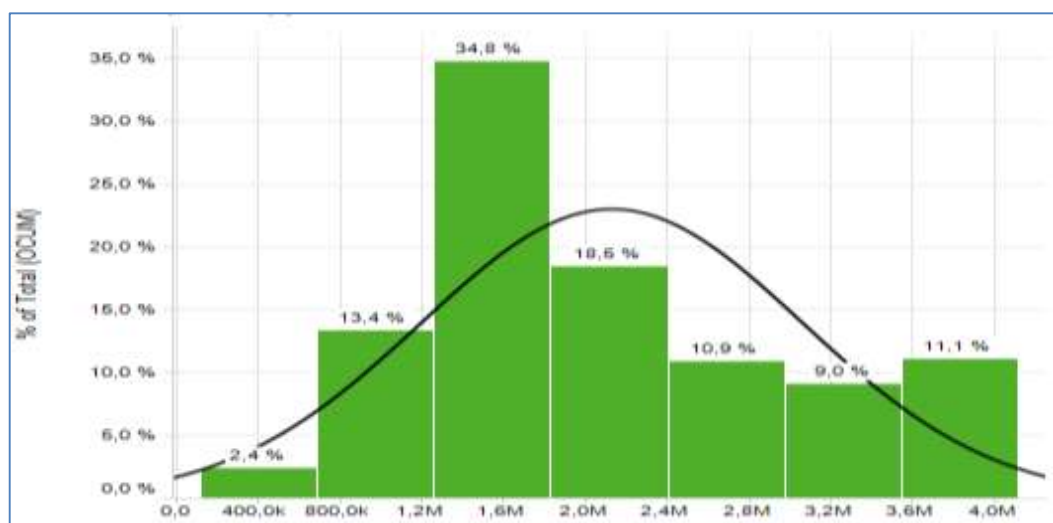


Figura 6 Histograma de acumulados incrementales por patron



La metodología de estimación de perfiles incrementales consiste en combinar la tendencia central de acumulados observada en el histograma y representada por el modelo de simulación, asignando probabilidades de ocurrencia entre un 75% y 95%, omitiendo los extremos máximos y mínimos del mismo; es decir se considerarán volúmenes entre 1.2 y 3.2 MBIs incrementales, con un valor más probable de 1.7 MBIs.

4 MODELO ANALÍTICO INTEGRADO

El presente capítulo incluye la definición de los escenarios o combinaciones de alternativas técnicas factibles en conjunción con las variables de incertidumbre y decisión que van a ser evaluadas mediante el modelo de optimización e incorporadas mediante un modelo analítico integrado.

4.1 ESCENARIOS DE DESARROLLO

Tal como se mencionó en el capítulo 2 todo escenario de desarrollo considerado y evaluado en este trabajo, se basa principalmente en actividades enfocadas en su orden al mantenimiento y aseguramiento de la curva base, la ejecución de los pilotos complementarios y la expansión del proceso de inyección de agua. La primera hace referencia a la adecuación de algunas facilidades con unas inversiones menores en los sistemas de producción y cuyos valores y perfiles entran al modelo de forma determinística. De otra parte la consolidación de los 17 pilotos para finales del año en curso con perfiles y flujos de caja también determinísticos y la tercera que busca llevar a cabo una expansión del modelo de inyección de agua hasta 42 patrones con espaciamientos promedio de 40 acres con el propósito de favorecer aproximadamente a 143 pozos.

4.1.1 Modelo Técnico Económico. Con base en las premisas mencionadas con anterioridad y la información del caso base, se construyó y adaptó un modelo de análisis técnico–económico en Excel (Anexo 3), que reflejara las distintas etapas del proceso de extracción, tratamiento y productos resultantes el cual permite evaluar las distintas alternativas involucrando variables de incertidumbre y decisión, calculando para cada iteración y basados en el modelo resultante de redes neuronales perfiles de producción de petróleo, gas, agua y fluidos totales para las alternativas , así como los flujos de caja, volúmenes asociados, costos de energía, impactos por optimización en el uso de nafta, pozos productores e inyectores activos entre otros.

Dicho análisis funciona a través de la simulación analítica integrada de los diferentes parámetros que definen la ejecución de alguna de las alternativas, facilitando la planificación del mismo y determinar los riesgos o probabilidades de cumplimiento. De igual forma el modelo integra y maneja cualquier cantidad de combinaciones posibles de tipo técnico, sincronizando paramétricos económicos para múltiples escenarios a través del análisis de sensibilidad y métodos estadísticos.

El modelo se basa en un volumen técnico objetivo a desarrollar para cada patrón y sus efectos en pozos aledaños que se ven favorecidos por efecto de mantenimiento de presión y barrido. De otra parte permite hacer sensibilidades a las mejores fechas de entrada de los patrones completos, el ritmo de perforación y conversiones para el mismo y las tasas de inyección promedio.

Este ejercicio genera perfiles probabilísticos de producción, permitiendo recorrer distintas alternativas de desarrollo, con el fin de maximizar la función objetivo buscando la mejor rentabilidad del proyecto.

Es fundamental recalcar que el modelo integrado refleja el caso base en lo concerniente a los 42 patrones, los pozos influenciados, los volúmenes asociados para el escenario y los componentes financieros marco, sentando las bases para poder obtener a partir de este punto, un número significativo de sensibilidades para los escenarios alternativos que permitan tomar decisiones frente a la estrategia de explotación y volúmenes a comprometer, principalmente en circunstancias de precios de mercado cambiantes y en espera del seguimiento financiero para los parámetros planteados a partir de las optimizaciones especialmente en costos de operación hechos por la organización.

De igual forma, tal como se permite la variación dentro de unos rangos y probabilidades de los perfiles tipo, y pozos afectados, se consideró que dicho

efecto y variación se hiciera en el modelo económico para los costos operativos, costos de capital, precios de venta, entre otros.

Para llevar a cabo las distintas combinaciones, y el análisis de escenarios y/o alternativas bajo riesgo e incertidumbre, se incluyeron en el modelo analítico 26 variables de incertidumbre (20 financieras, 6 técnicas), 6 variables de decisión y 354 de respuesta, siendo solicitadas estas últimas tanto en forma escalar (p.e.: VPN, EFI, TIR) como de vectores (p.e.: flujos de caja, curvas de producción, entre otros). (Ver Anexo 4)

4.1.2 Premisas Financieras. El campo estudio es operado por Ecopetrol y se rige bajo las siguientes premisas financieras y drivers económicos así:

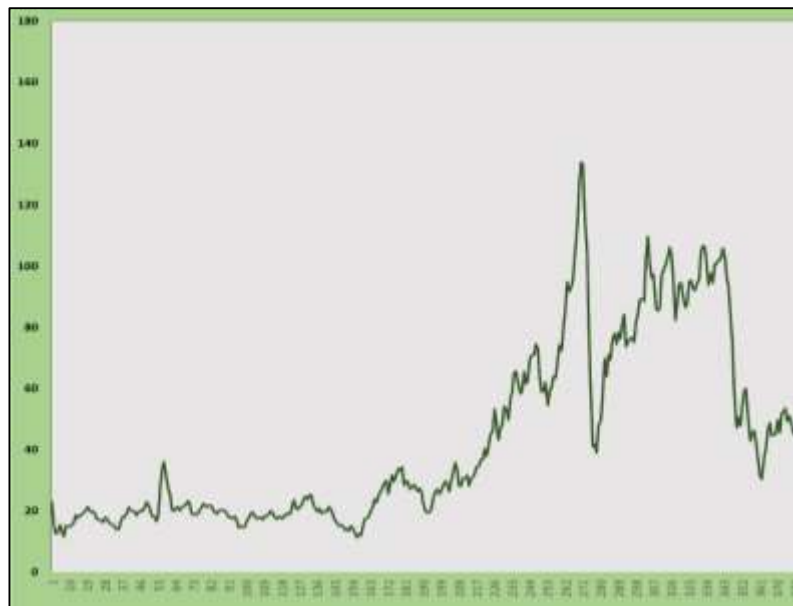
Tasa descuento:	10%
TRM:	3.000 COP/USD
Regalías:	8% - 16% Variables
Drivers OPEX:	Fluido: 0,16 USD/BI Agua Inyectada: 0,15 USD/BI Crudo: 0,016 USD/BI
Precio venta:	Ajustado por series de Tiempo
Costo abandono:	0.55 MUSD/pozo

Para el componente económico referente a los precios de venta, se llevó a cabo una sensibilidad de ajuste mediante series de tiempo utilizando los históricos de precios desde el año 1961 y con un segmento independiente a partir del año 2008 para pronosticar las vigencias 2018 a 2021, posteriormente se mantuvieron precios constantes. Más aún cuando la premisa de aprobación o sanción de proyectos de la compañía está sujeta a precios de 45 y 50 dólares por barril, precios sobre los cuales se hará todo el análisis y recomendaciones.

4.1.3 Proyección precio BRENT series de tiempo. Para llevar a cabo el ajustede precio mediante series de tiempo, fue utilizada la herramienta @RISK de PALISADE, la cual cuenta con ajustes de modelos mediante 5 tipos de

predicción, y en el cual se incluyeron los precios históricos del petróleo BRENT desde el año 1961 tal como se ve en la Figura 7.

Figura 7. Históricos precios BRENT 1961 – 2017



A partir de esta información, la herramienta busca los mejores ajustes y los prioriza para decidir sobre cual se hará la predicción, basado en el criterio de información AIC, donde el valor más bajo corresponde al modelo de mejor ajuste como se ve en las Figuras 8 y 9.

Figura 8. Modelos de ajuste precio BRENT


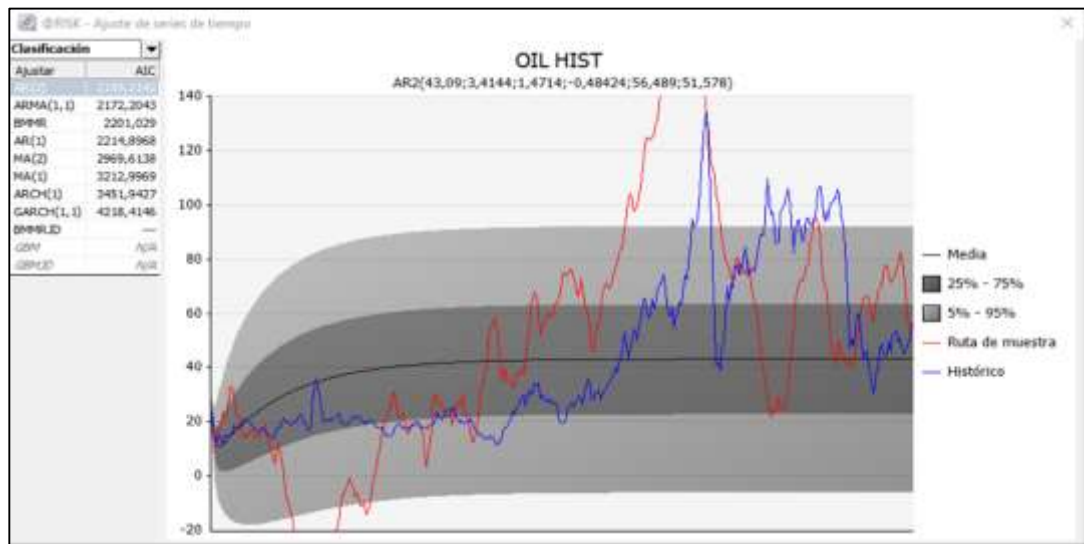


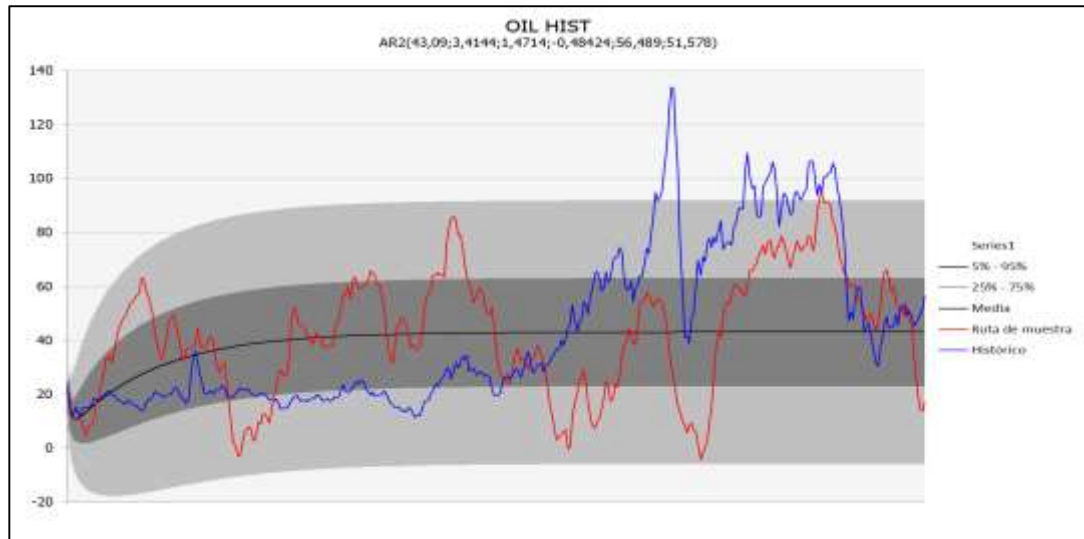
Figura 9. Zona de ajuste para últimos 10 años



Como se puede observar en los valores AIC de ajuste, el que presenta el menor valor es el correspondiente al Modelo Geométrico Browniano, tomando así la decisión de pronosticar con este el precio para los siguientes cuatro periodos bajo un modelo probabilístico que se modifica en cada iteración y ver cual sería

el precio promedio a evaluar en las siguientes vigencias, tal como se ve en la Figura 10.

Figura 10. Proyección de precios y valores medios para crudo BRENT



Si se observa la oscilación de las predicciones un valor promedio entre los 45 y 55 dólares por barril es un valor coherente, a pesar de ver una temporalidad futura con visiones bastantes optimistas, muy seguramente asociado a estacionalidades correspondientes a los años 2010 a 2013, sin embargo y validado el modelo se decidió continuar la evaluación con precios que oscilan entre los 30 y los 60 dólares por barril.

5 MODELO DE OPTIMIZACIÓN E INCERTIDUMBRE

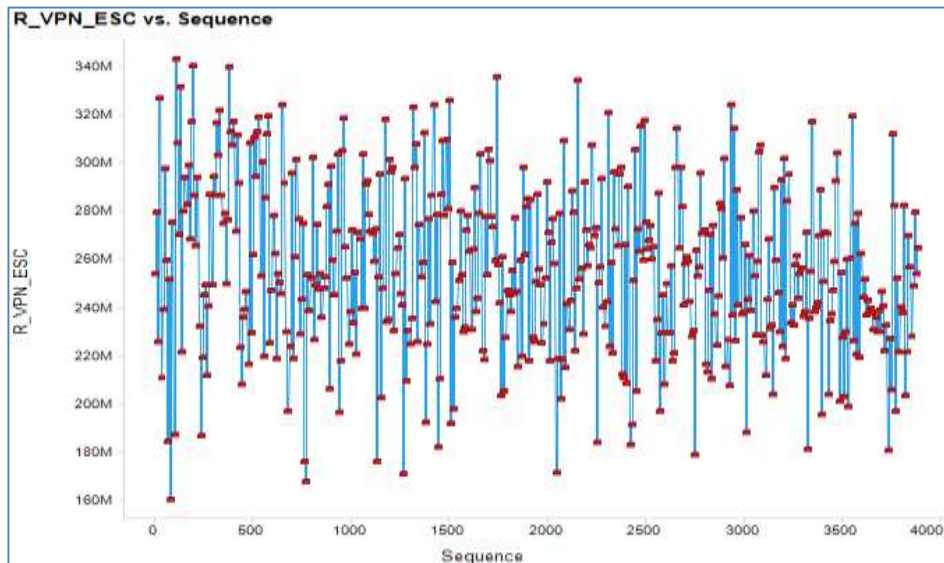
Como ya se había mencionado, la generación de escenarios se realiza usando la herramienta DMS™, la cual dispone de dos procesos iterativos anidados, que funcionan así: un ciclo externo combina las decisiones para crear escenarios; y se ajusta en cada nueva iteración; al paso de cada iteración externa o de decisión, se activa el algoritmo estocástico para recrear las realizaciones que definirán las incertidumbres de cada alternativa

El modelo analítico integrado se compone por varias condiciones y ecuaciones que representan la dinámica de producción a lo largo de todo el proceso. Generando así perfiles para pozos activos, perfiles para agua inyectada, requerimientos de dilución, consumo eléctrico y factores de éxito de las operaciones, todo ello logra generar el perfil de producción del campo; sujeto a las condiciones de facilidades establecidas y límite económico.

Por último cada perfil resultante es integrado al modelo económico para transformarlo en perfil de ingresos; perfil de costos, flujo de caja y buscar para cada iteración factible una maximización de la función objetivo para un precio de 45 USD/BL y sobre los cuales mostraremos resultados.

Por razones de complejidad del yacimiento y la sensibilidad económica que tiene el modelo en varios de sus parámetros, la función objetivo para indicar valor es el Valor Presente Neto (VPN) para el P50 de 45 USD/BL Figura 11

Figura 11. Iteraciones buscando maximizar el VPN



El proceso iterativo logra durante la simulación y a medida que recorre las diferentes combinaciones, maximizar algunos escenarios con mejores VPN, descartando a medida que avanza, aquellas que destruyen valor y concentrándose en aquellas que impactan positivamente la función objetivo. Cabe resaltar que este ejercicio, en comparación con la visión determinística cuenta con 500 combinaciones adicionales y 4000 iteraciones que fortalecen el análisis y soporta cualquier decisión que se tome a partir de esta metodología. Los resultados para volúmenes técnicos y perfiles de producción para los escenarios en evaluación se resumen según su justificación de la siguiente forma:

5.1 EXPANSIÓN INYECCIÓN DE AGUA 2018

Con este escenario se busca favorecer la producción incremental temprana de los pozos existentes y está sujeto a los tiempos requeridos de maduración y aprobación de inversiones posteriores al cierre técnico de los pilotos 2017; este escenario es considerado como el más optimista en términos de cronograma y calendarización de actividades.

Esta alternativa se evaluó en combinación con las curvas básica y básica incremental mostradas en el capítulo 3, Las Figuras 12 y 13 muestran los resultados probabilísticos de perfiles y acumulados para este escenario.

Figura 12. Perfiles Producción de petróleo expansión @ 2018

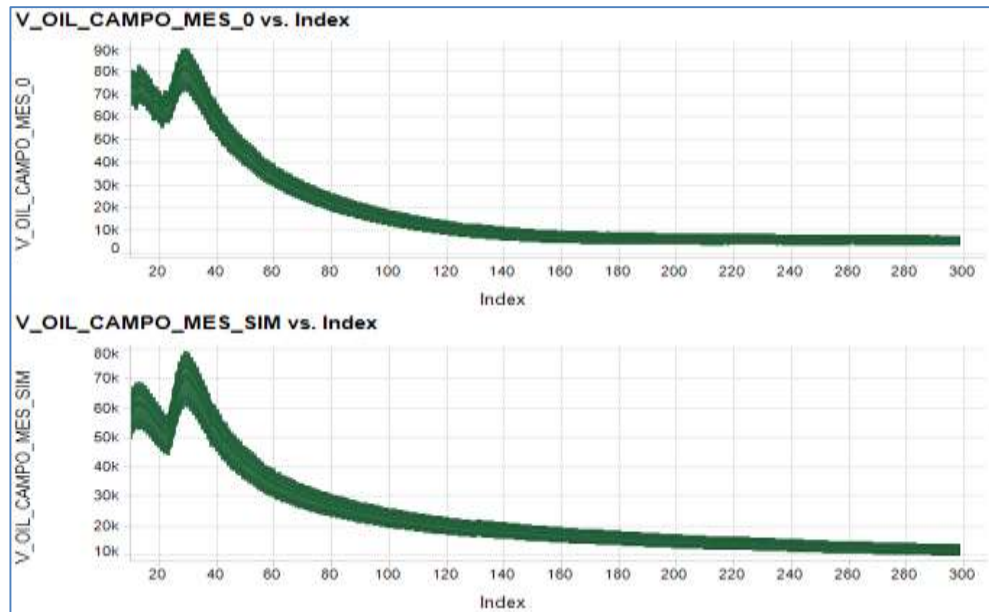
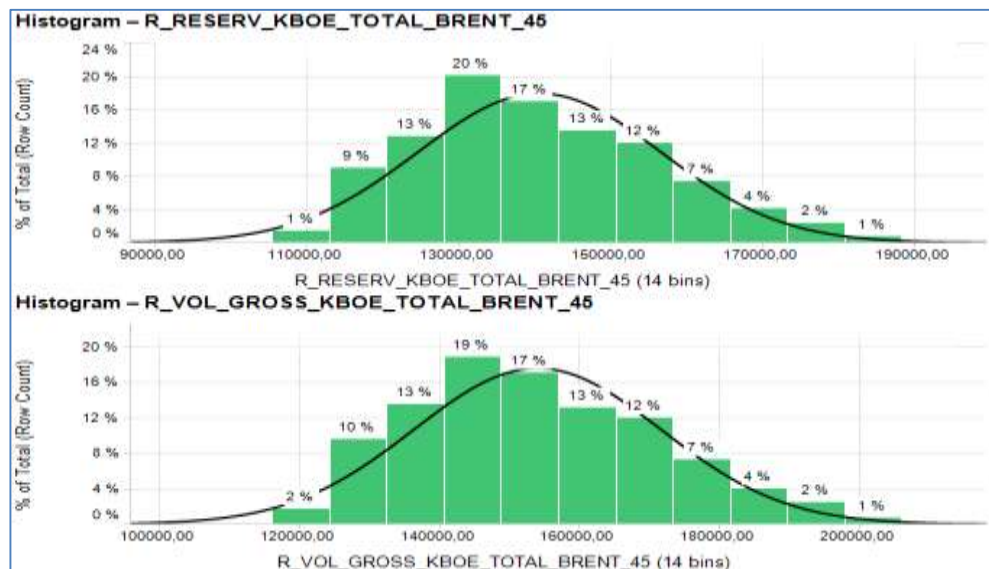



Figura 13. Histograma reservas y volúmenes técnicos @ 2018



Una vez obtenidos los perfiles de producción y los volúmenes con su respectiva probabilidad de ocurrencia, se corrió para cada escenario el modelo económico representativo del campo como proyecto completo y se comparó con el valor presente neto de la curva básica de producción que según el percentil oscila entre 360 y 450 MUSD Figura 14

Figura 14 VPN vs Reservas WF @ 2018



5.2 EXPANSIÓN INYECCIÓN DE AGUA 2019

Como parte de los escenarios evaluados y tratando de tener una visión de expansión del proceso de inyección de agua a 40 acres en un mediano plazo y sujeto a tiempos de maduración diferentes al caso anterior, se realizó el mismo ejercicio y sensibilidades a partir del año 2019.

De igual forma al caso previo, esta alternativa combina el efecto resultante de la inyección en conjunto con las curvas básica y básica incremental del capítulo 3, obteniendo los resultados volumétricos que se ilustran en las Figuras 15 y 16.

Figura 15 Perfiles Producción de petróleo expansión @ 2018

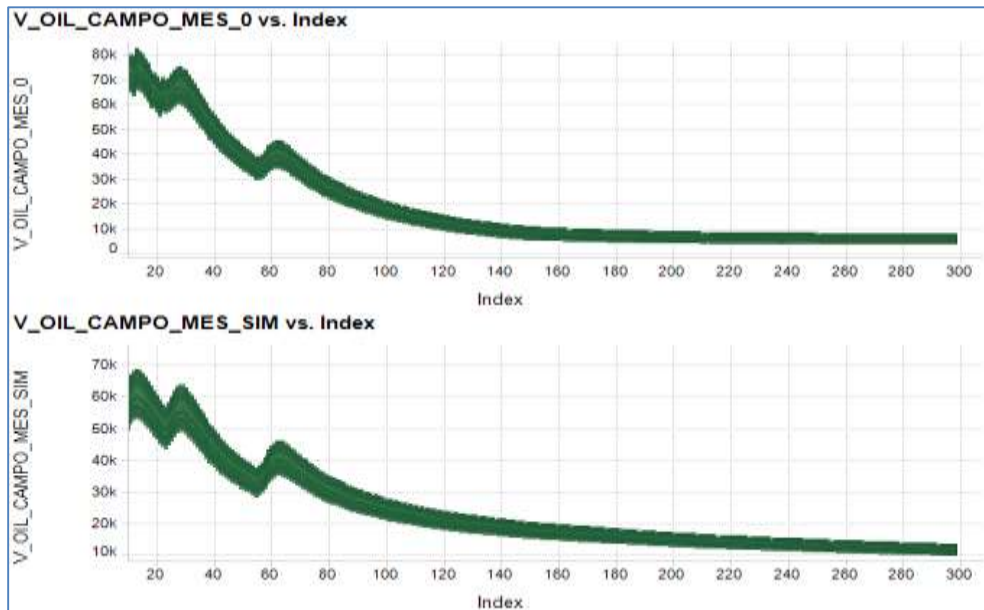

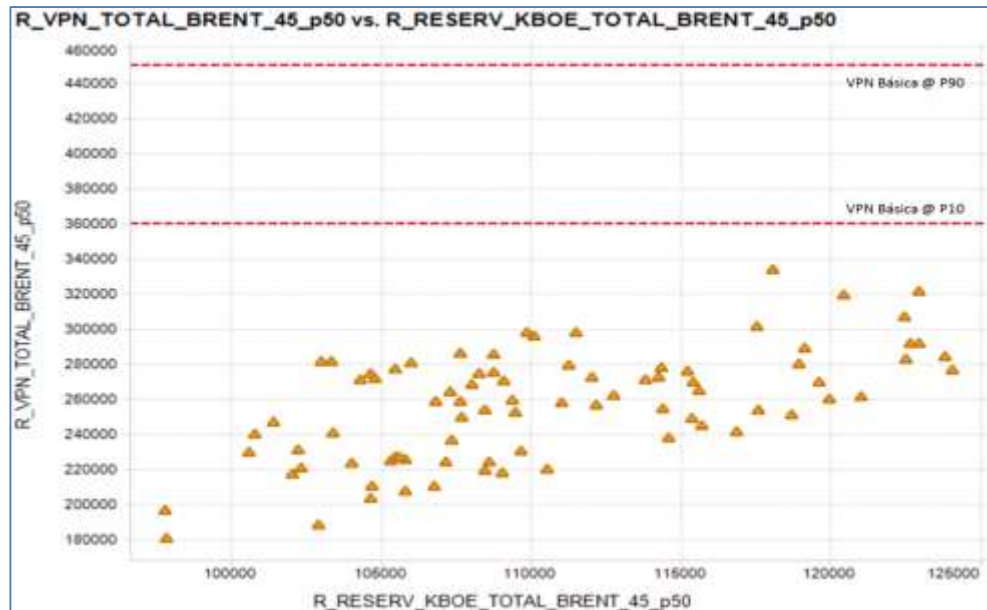


Figura 16 Histograma reservas y volúmenes técnicos @ 2019



El modelo económico para cada curva de producción estimada, también fue corrido como proyecto completo y se llevó a cabo la comparación con el valor presente neto de la curva básica de producción, indicado con la línea roja para los percentiles P10 y P90, respectivamente Figura 17

Figura 17 VPN vs Reservas WF @ 2018



5.3 EXPANSIÓN INYECCIÓN DE AGUA 2020:

La última alternativa evaluada en lo referente a tiempos de maduración y expansión del proyecto de inyección de agua a 40 acres fue la opción del año 2020. Esta visión luce como una de las más realistas, además de permitir la evolución y toma representativa de resultados para todos los pilotos.

La combinación de esta alternativa, sus perfiles incrementales y las curvas básica e incremental arrojó los resultados volumétricos se ilustran en las Figuras 18 y 19.

Figura 18 Perfiles Producción de petróleo expansión @ 2020


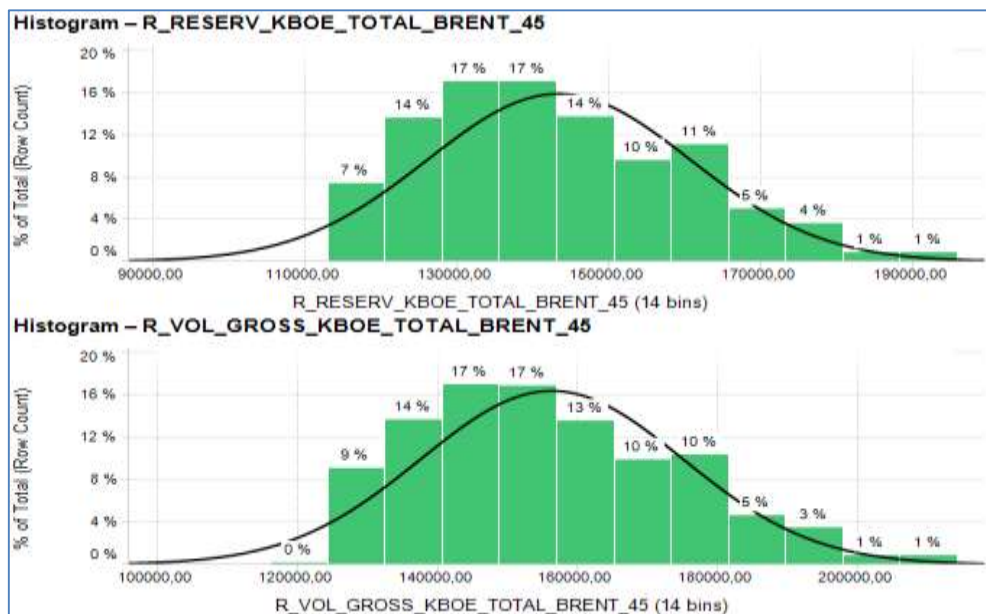
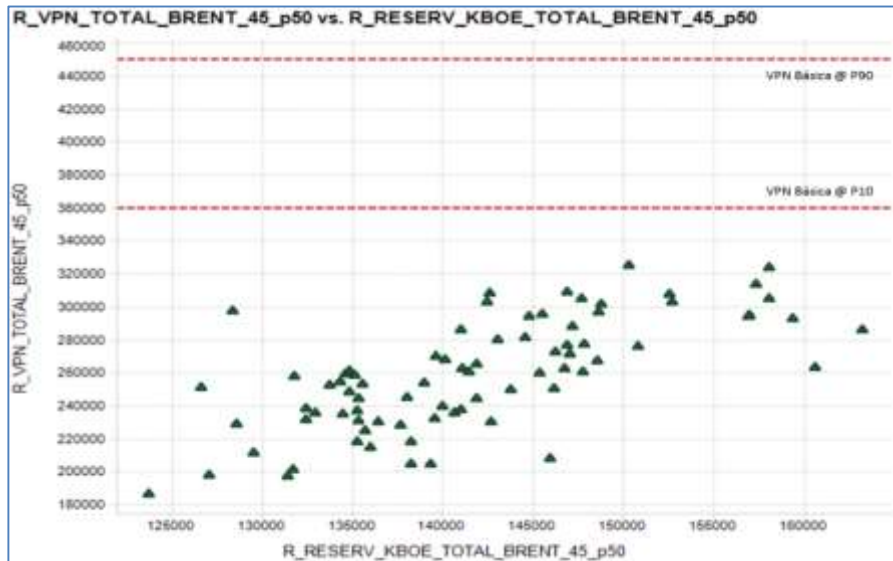


Figura 19 Histograma reservas y volúmenes técnicos @ 2020



Para tener una vista completa del proyecto total, se realizó la misma evaluación mediante el modelo económico para todos los perfiles de producción y los volúmenes obtenidos y nuevamente se comparó con el valor presente neto de la curva básica de producción Figura 20.

Figura 20 VPN vs Reservas WF @ 2020



CONCLUSIONES

El haber realizado más de 400 combinaciones factibles entre los distintos escenarios de desarrollo para el campo estudio, indica que en términos generales los rangos en que se mueven las reservas de petróleo son similares en las tres alternativas oscilando entre los 130 y los 160 MBIs dentro de la zona central de la campana.

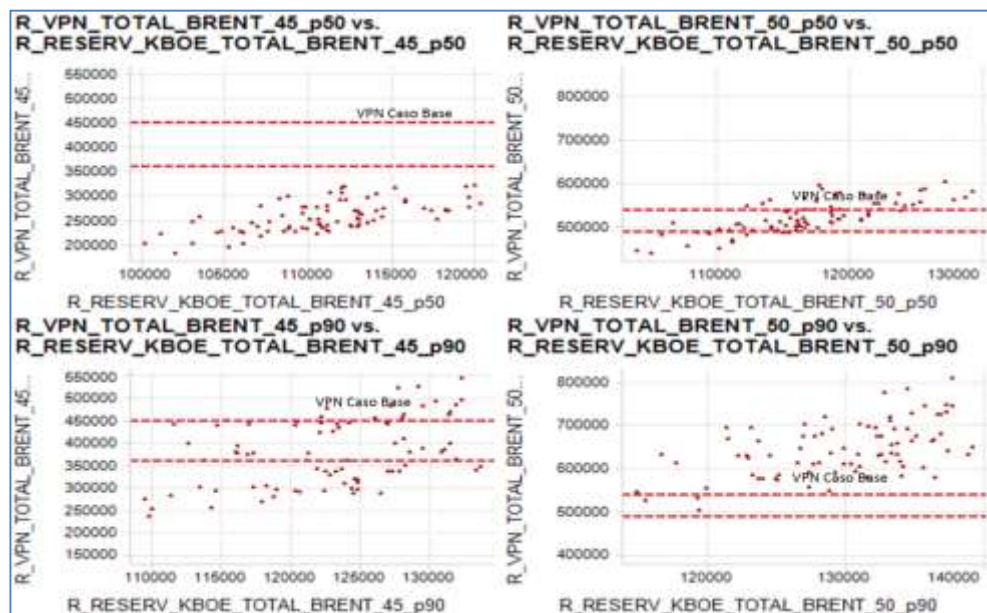
Al detallar las colas o límites máximos para las estrategias de expansión en el año 2019 y 2020, estas indican la posibilidad de obtener algunos barriles adicionales como efecto de sostenimiento de presión a partir del agua inyectada por los pilotos.

De acuerdo con los análisis realizados se podría llegar a la conclusión de que cualquier alternativa en lo concerniente a reservas podría implementarse en el campo sin mayor impacto; sin embargo, y si se discretean los componentes financieros, en especial para precios de 45 USD/BI en su percentil 50, la actividad incremental estaría restando valor a la curva de VPN actual del campo en cerca de 80 MUSD en comparación con el escenario bajo y casi 180 MUSD en el escenario alto, siendo cierto que el proyecto integrado en ningún caso se hace negativo, el proyecto incremental si lo es.

RECOMENDACIONES

Es importante ubicar a los tomadores de decisión en términos de probabilidad de ocurrencia o percentiles, y ver si en algún escenario con mejores tasas de producción incremental, costos operativos óptimos y constantes, inversiones de capital con curva de aprendizaje o mejores precios de venta, la visión preliminar puede verse favorecida. Para ello se realizó la evaluación financiera para otros escenarios de precios y en distintos percentiles y se logró observar que para condiciones más favorables e incluso a precios corporativos visión Ecopetrol, varias opciones generan valor adicional a la línea base de VPN Figura 21.

Figura 21 VPN vs Reservas @ 45 - 50 USD Volúmenes P50 y P90



En términos generales la promesa volumétrica del campo estudio, podría mantenerse como factible, sujeta a los resultados obtenidos de los pilotos en ejecución, y la favorabilidad tanto en precios de mercado como de perfiles de producción.

BIBLIOGRAFIA

Al-Bulushi, N., Araujo, M., Kraaijveld, M., & Jing, X. D. (2007, January 1). Predicting Water Saturation Using Artificial Neural Networks (ANNs). Society of Petrophysicists and Well-Log Analysts.

Ali, J. K. (1994, January 1). Neural Networks: A New Tool for the Petroleum Industry? Society of Petroleum Engineers. doi:10.2118/27561-MS

Goda, H. M., El-M Shokir, E. M., Fattah, K. A., & Sayyoub, M. H. (2003, January 1). Prediction of the PVT Data using Neural Network Computing Theory. Society of Petroleum Engineers. doi:10.2118/85650-MS

Kumoluyi, A. O. (1995, January 1). Higher-Order Neural Networks in Petroleum Engineering. Society of Petroleum Engineers. doi:10.2118/27905-MS

McCormack, M. P. (1991, January 1). Neural Networks In the Petroleum Industry. Society of Exploration Geophysicists.

Mohaghegh, S." Virtual Intelligence and its Applications in Petroleum Engineering. Part 1. Artificial Neural Networks", JPT – Journal of Petroleum Technology, September 2000.

Nakutnyy, P., Asghari, K., & Torn, A. (2008, January 1). Analysis of Waterflooding Through Application of Neural Networks. Petroleum Society of Canada. doi:10.2118/2008-190

Nikraves, M., Kovscek, A. R., Jonston, R. M., and Patsek, T. W. "Prediction of Formation Damage During the Fluid Injection into Fractured Low Permeability Reservoirs via Neural networks," SPE 31103, Proceedings, SPE Formation Damage Symposium, Feb. 16-18, 1996, Lafayette, LA.

Ouense, A., Zellou, A., Basinski, P. M., and Head, C. F. "Use of Neural Networks in Tight Gas Fractured Reservoirs: Application to San Juan Basin," SPE 39965, Proceedings, Rocky Mountain Regional Meeting / Low Permeability Reservoir Symposium, April 5-8, 1998, Denver, CO.

Shelley, R., Stephenson, S., Haley, W., Craig, E. "Red Fork Completion Analysis with the Aid of Artificial Neural Networks," SPE 39963, Proceedings, Rocky

Mountain Regional Meeting / Low Permeability Reservoir Symposium, April 5-8, 1998, Denver, CO.

Ternyik, J., Bilgesu, I., Mohaghegh, S., and Rose, D., "Virtual Measurement in Pipes, Part 1: Flowing Bottomhole Pressure Under Multi-phase Flow and Inclined Wellbore Conditions," SPE 30975, Proceedings, SPE Eastern Regional Conference and Exhibition, September 19-21, 1995, Morgantown, West Virginia.

Wong, P. M., Henderson, D. J., Brooks, L. J. "Permeability Determination using Neural Networks in the Ravva Field, Offshore India," SPE Reservoir Evaluation and Engineering 1 (2), 1998.

Zellou, A., Ouense, A., and Banik, A. "Improved Naturally Fractured Reservoir Characterization Using Neural networks, Geomechanics and 3-D Seismic," SPE 30722, Proceedings, SPE Annual Technical Conference and Exhibition, October 22-25, 1995, Dallas, TX.

ANEXOS

Anexo A. Variables empleadas en el modelo analítico

Variables de incertidumbre modelo analítico

I_ABANDONO	I_Incr_1A_LINEA	I_MONIYT_PLT
I_BASICA	I_Incr_INY	I_MOVIL_COMP
I_Calidad	I_Incr_PERIF	I_MOVIL_PERF
I_CAPEX_PERF	I_MANT_INY	I_OIL_TRAT
I_CONV	I_MANT_PROD	I_PLANTA_DESASF
I_COSTO_FIJO	I_MONIT_ILT	I_PLANTA_MEJORAMIENTO
I_COSTO_SEMIFIJO	I_MONIT_MUESTREO	I_TARIF_DESASFALTADO
I_FACTOR_REEMPLAZO_NAFTA	I_MONIT_RUIDO	I_WINY_COST
I_FLUID_TRAT	I_MONIT_TRASADOR	

NOTA: La letra I al inicio del nombre de cada variable indica que se trata de una variable de incertidumbre

Variables de decisión modelo analítico

D_DESASFALTADO
D_ESCENARIO
D_FAC_ALT
D_MADURACION
D_PROD_AGUA
D_WIR

NOTA: La letra D al inicio del nombre de cada variable indica que se trata de una variable de decisión

Variables respuesta modelo analítico

R_AHORRO_BL_NAFTA_BASICA	R_LE_TOTAL_BRENT_45	R_PV_UTC_TOTAL_BRENT_35	R_VOL_GROSS_KBOE_INCREM_BRENT_35
R_AHORRO_BL_NAFTA_TOTAL	R_LE_TOTAL_BRENT_50	R_PV_UTC_TOTAL_BRENT_45	R_VOL_GROSS_KBOE_INCREM_BRENT_45
R_CAPEX_BASICA_KUSD	R_LE_TOTAL_BRENT_60	R_PV_UTC_TOTAL_BRENT_50	R_VOL_GROSS_KBOE_INCREM_BRENT_50
R_CAPEX_TOTAL_KUSD	R_LIFTCOST_BASICA_BRENT_30	R_PV_UTC_TOTAL_BRENT_60	R_VOL_GROSS_KBOE_INCREM_BRENT_60
R_CAPEX_TOTAL_SIN_ABANDONO_KUSD	R_LIFTCOST_BASICA_BRENT_35	R_RESERV_KBOE_INCREM_BRENT_30	R_VOL_GROSS_KBOE_TOTAL
R_DEVELOPCOST_BASICA_BRENT_30	R_LIFTCOST_BASICA_BRENT_45	R_RESERV_KBOE_INCREM_BRENT_35	R_VOL_GROSS_KBOE_TOTAL_BRENT_30
R_DEVELOPCOST_BASICA_BRENT_35	R_LIFTCOST_BASICA_BRENT_50	R_RESERV_KBOE_INCREM_BRENT_45	R_VOL_GROSS_KBOE_TOTAL_BRENT_35
R_DEVELOPCOST_BASICA_BRENT_45	R_LIFTCOST_BASICA_BRENT_60	R_RESERV_KBOE_INCREM_BRENT_50	R_VOL_GROSS_KBOE_TOTAL_BRENT_45
R_DEVELOPCOST_BASICA_BRENT_50	R_LIFTCOST_INCREM_BRENT_30	R_RESERV_KBOE_INCREM_BRENT_60	R_VOL_GROSS_KBOE_TOTAL_BRENT_50
R_DEVELOPCOST_BASICA_BRENT_60	R_LIFTCOST_INCREM_BRENT_35	R_RESERV_KBOE_TOTAL_BRENT_30	R_VOL_GROSS_KBOE_TOTAL_BRENT_60
R_DEVELOPCOST_INCREM_BRENT_30	R_LIFTCOST_INCREM_BRENT_45	R_RESERV_KBOE_TOTAL_BRENT_35	R_VPI_BASICA_BRENT_30
R_DEVELOPCOST_INCREM_BRENT_35	R_LIFTCOST_INCREM_BRENT_50	R_RESERV_KBOE_TOTAL_BRENT_45	R_VPI_BASICA_BRENT_35
R_DEVELOPCOST_INCREM_BRENT_45	R_LIFTCOST_INCREM_BRENT_60	R_RESERV_KBOE_TOTAL_BRENT_50	R_VPI_BASICA_BRENT_45
R_DEVELOPCOST_INCREM_BRENT_50	R_LIFTCOST_TOTAL_BRENT_30	R_RESERV_KBOE_TOTAL_BRENT_60	R_VPI_BASICA_BRENT_50
R_DEVELOPCOST_INCREM_BRENT_60	R_LIFTCOST_TOTAL_BRENT_35	R_RESERV_OIL_KBO_INCREM_BRENT_30	R_VPI_BASICA_BRENT_60
R_DEVELOPCOST_TOTAL_BRENT_30	R_LIFTCOST_TOTAL_BRENT_45	R_RESERV_OIL_KBO_INCREM_BRENT_35	R_VPI_INCREM_BRENT_30
R_DEVELOPCOST_TOTAL_BRENT_35	R_LIFTCOST_TOTAL_BRENT_50	R_RESERV_OIL_KBO_INCREM_BRENT_40	R_VPI_INCREM_BRENT_35
R_DEVELOPCOST_TOTAL_BRENT_45	R_LIFTCOST_TOTAL_BRENT_60	R_RESERV_OIL_KBO_INCREM_BRENT_45	R_VPI_INCREM_BRENT_45
R_DEVELOPCOST_TOTAL_BRENT_50	R_NAFTA_BL_COMPRA_BASICA	R_RESERV_OIL_KBO_INCREM_BRENT_50	R_VPI_INCREM_BRENT_50
R_DEVELOPCOST_TOTAL_BRENT_60	R_NAFTA_BL_COMPRA_TOTAL	R_RESERV_OIL_KBO_TOTAL_BRENT_30	R_VPI_INCREM_BRENT_60

R_EFI_BASICA_BRENT_30	R_OCUM_1A_LINEA	R_RESERV_OIL_KBO_TOTAL_BRENT_35	R_VPI_TOTAL_BRENT_30
R_EFI_BASICA_BRENT_35	R_OCUM_INY	R_RESERV_OIL_KBO_TOTAL_BRENT_45	R_VPI_TOTAL_BRENT_35
R_EFI_BASICA_BRENT_45	R_OCUM_PERIFERIA	R_RESERV_OIL_KBO_TOTAL_BRENT_50	R_VPI_TOTAL_BRENT_45
R_EFI_BASICA_BRENT_50	R_OCUM_TOTAL_CAMPO	R_RESERV_OIL_KBO_TOTAL_BRENT_60	R_VPI_TOTAL_BRENT_50
R_EFI_BASICA_BRENT_60	R_OIL_GROSS_KSTB_BASICA	R_TIR_BASICA_BRENT_30	R_VPI_TOTAL_BRENT_60
R_EFI_INCREM_BRENT_30	R_OIL_GROSS_KSTB_INCREM	R_TIR_BASICA_BRENT_35	R_VPN_BASICA_BRENT_30
R_EFI_INCREM_BRENT_35	R_OIL_GROSS_KSTB_TOTAL	R_TIR_BASICA_BRENT_45	R_VPN_BASICA_BRENT_35
R_EFI_INCREM_BRENT_45	R_OILCUM_BAS	R_TIR_BASICA_BRENT_50	R_VPN_BASICA_BRENT_45
R_EFI_INCREM_BRENT_50	R_OPEX_BASICA	R_TIR_BASICA_BRENT_60	R_VPN_BASICA_BRENT_50
R_EFI_INCREM_BRENT_60	R_OPEX_CAMPO	R_TIR_INCREM_BRENT_30	R_VPN_BASICA_BRENT_60
R_EFI_TOTAL_BRENT_30	R_OPEX_NAFTA	R_TIR_INCREM_BRENT_35	R_VPN_INCREM_BRENT_30
R_EFI_TOTAL_BRENT_35	R_OPEX_NAFTA_BASICA	R_TIR_INCREM_BRENT_45	R_VPN_INCREM_BRENT_35
R_EFI_TOTAL_BRENT_45	R_OPEX_NAFTA_BASICA_NO_OP T	R_TIR_INCREM_BRENT_50	R_VPN_INCREM_BRENT_45
R_EFI_TOTAL_BRENT_50	R_OPEX_NAFTA_BASICA_OPT	R_TIR_INCREM_BRENT_60	R_VPN_INCREM_BRENT_50
R_EFI_TOTAL_BRENT_60	R_OPEX_NAFTA_TOTAL_NO_OPT	R_TIR_TOTAL_BRENT_30	R_VPN_INCREM_BRENT_60
R_GCUM_1A_LINEA	R_OPEX_NAFTA_TOTAL_OPT	R_TIR_TOTAL_BRENT_35	R_VPN_TOTAL_BRENT_30
R_GCUM_BASICA	R_PAYOUT_TOTAL_BRENT_30	R_TIR_TOTAL_BRENT_45	R_VPN_TOTAL_BRENT_35
R_GCUM_INY	R_PAYOUT_TOTAL_BRENT_35	R_TIR_TOTAL_BRENT_50	R_VPN_TOTAL_BRENT_45
R_GCUM_PERIFERIA	R_PAYOUT_TOTAL_BRENT_45	R_TIR_TOTAL_BRENT_60	R_VPN_TOTAL_BRENT_50
R_GCUM_TOTAL_CAMPO	R_PAYOUT_TOTAL_BRENT_50	R_VOL_GROSS_KBOE_BASICA	R_VPN_TOTAL_BRENT_60
R_LE_BASICA_BRENT_30	R_PAYOUT_TOTAL_BRENT_60	R_VOL_GROSS_KBOE_BASICA_BRENT_3 0	R_WCUM_1A_LINEA
R_LE_BASICA_BRENT_35	R_PV_UTC_BASICA_BRENT_30	R_VOL_GROSS_KBOE_BASICA_BRENT_3 5	R_WCUM_BASICA
R_LE_BASICA_BRENT_45	R_PV_UTC_BASICA_BRENT_35	R_VOL_GROSS_KBOE_BASICA_BRENT_4 5	R_WCUM_INY
R_LE_BASICA_BRENT_50	R_PV_UTC_BASICA_BRENT_45	R_VOL_GROSS_KBOE_BASICA_BRENT_5 0	R_WCUM_PERIFERIA
R_LE_BASICA_BRENT_60	R_PV_UTC_BASICA_BRENT_50	R_VOL_GROSS_KBOE_BASICA_BRENT_6 0	R_WCUM_TOTAL_CAMPO
R_LE_TOTAL_BRENT_30	R_PV_UTC_BASICA_BRENT_60	R_VOL_GROSS_KBOE_INCREM	R_WINCUM_1A_LINEA
R_LE_TOTAL_BRENT_35	R_PV_UTC_TOTAL_BRENT_30	R_VOL_GROSS_KBOE_INCREM_BRENT_ 30	R_WINCUM_BASICA

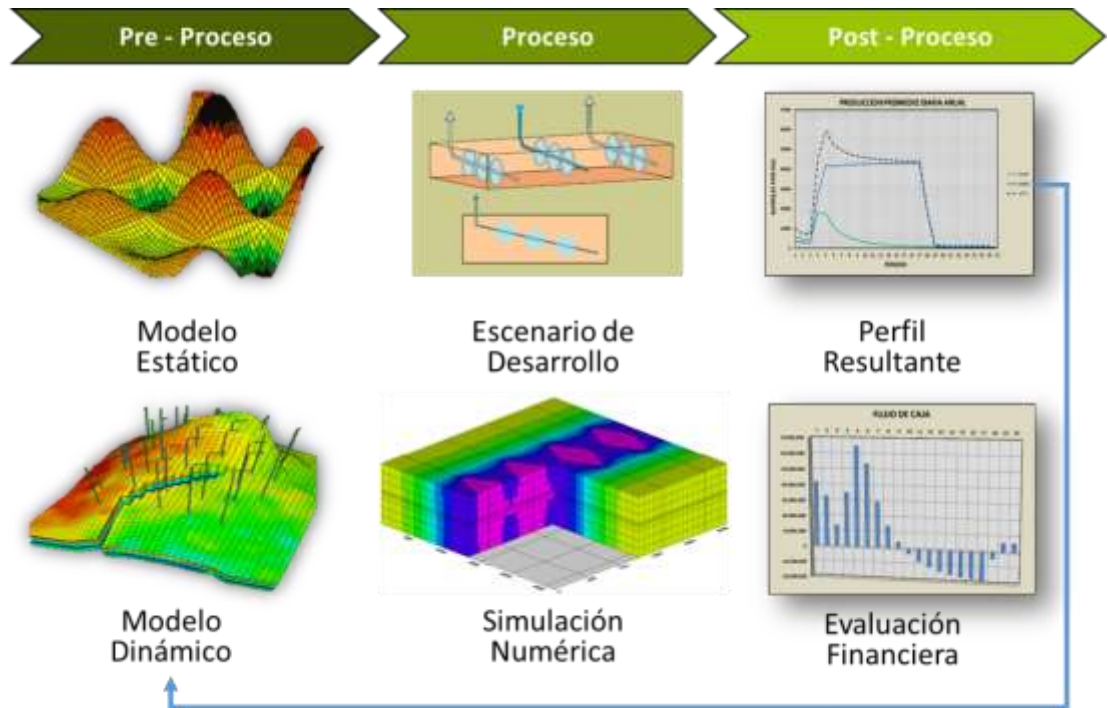
NOTA: La letra R al inicio del nombre de cada variable indica que se trata de un escalar respuesta

V_AÑO	V_GPR_CHSW40	V_OPR_CHSW125	V_WPR_CH59
V_CAPEX_TOTAL_ANUAL_KUSD	V_GPR_CHSW44	V_OPR_CHSW13	V_WPR_CH60
V_ENERGIA_BFPD	V_GPR_CHSW46	V_OPR_CHSW23	V_WPR_CH68
V_GAS_BASICA_SIM_MES	V_GPR_CHSW49	V_OPR_CHSW25	V_WPR_CH90H
V_GAS_BASICA_WF_MES	V_GPR_CHSW65	V_OPR_CHSW28	V_WPR_CH91H
V_GAS_PROD_CAMPO	V_INY_ACT	V_OPR_CHSW30	V_WPR_CH92H
V_GAS_WF_1LIN_MES	V_INY_ACT_BASICA_WF_MES	V_OPR_CHSW34	V_WPR_CH99
V_GAS_WF_INY_MES	V_NAFTA_CAMPO	V_OPR_CHSW40	V_WPR_CHSW06
V_GAS_WF_PERIM_MES	V_NAFTA_REEMPLAZO	V_OPR_CHSW44	V_WPR_CHSW12
V_GPR_112	V_OIL_BASICA_0_MES	V_OPR_CHSW46	V_WPR_CHSW125
V_GPR_146	V_OIL_BASICA_SIM_MES	V_OPR_CHSW49	V_WPR_CHSW13
V_GPR_148	V_OIL_BASICA_WF_MES	V_OPR_CHSW65	V_WPR_CHSW23
V_GPR_152	V_OIL_PROD_CAMPO	V_POZOS_ACT_BASICA_WF_MES	V_WPR_CHSW25
V_GPR_166	V_OIL_WF_1LIN_MES	V_PROD_ACT	V_WPR_CHSW28
V_GPR_174	V_OIL_WF_INY_MES	V_WAT_PROD_CAMPO	V_WPR_CHSW30
V_GPR_248	V_OIL_WF_PERIM_MES	V_WATER_BASICA_0_MES	V_WPR_CHSW34
V_GPR_249	V_OPR_112	V_WATER_BASICA_SIM_MES	V_WPR_CHSW40
V_GPR_260	V_OPR_146	V_WATER_BASICA_WF_MES	V_WPR_CHSW44
V_GPR_359	V_OPR_148	V_WATER_WF_1LIN_MES	V_WPR_CHSW46
V_GPR_CH100	V_OPR_152	V_WATER_WF_INY_MES	V_WPR_CHSW49
V_GPR_CH117	V_OPR_166	V_WATER_WF_PERIM_MES	V_WPR_CHSW65
V_GPR_CH119	V_OPR_174	V_WINY_BASICA_SIM_MES	

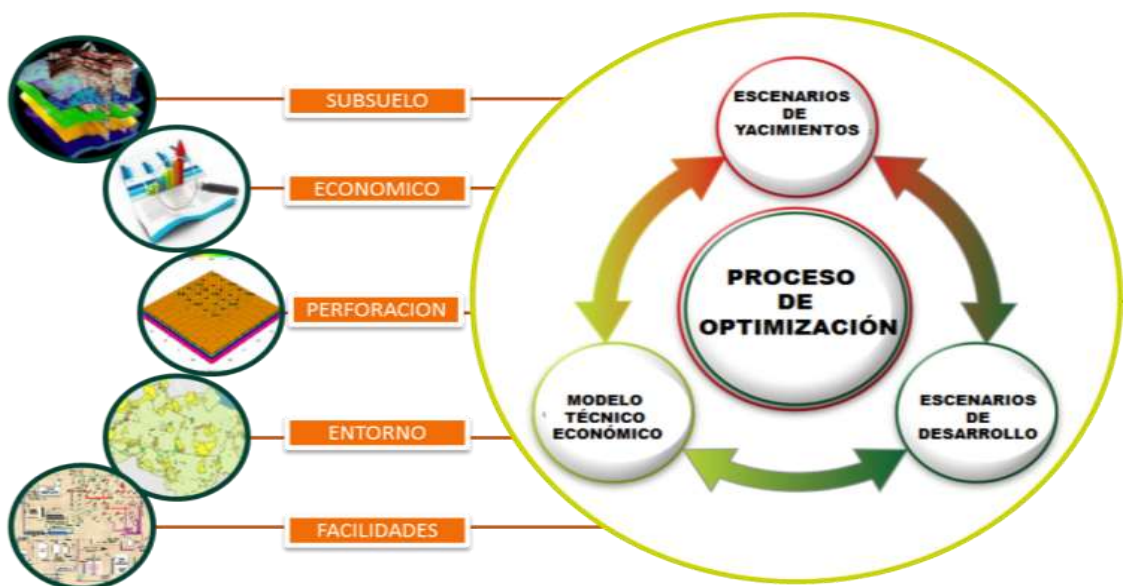
V_GPR_CH207	V_OPR_248	V_WINY_BASICA_WF_MES	
V_GPR_CH208	V_OPR_249	V_WINY_PROD_CAMPO	
V_GPR_CH209	V_OPR_260	V_WINY_WF_1LIN_MES	
V_GPR_CH221	V_OPR_359	V_WPR_112	
V_GPR_CH222	V_OPR_CH100	V_WPR_146	
V_GPR_CH226	V_OPR_CH117	V_WPR_148	
V_GPR_CH249	V_OPR_CH119	V_WPR_152	
V_GPR_CH29	V_OPR_CH207	V_WPR_166	
V_GPR_CH31	V_OPR_CH208	V_WPR_174	
V_GPR_CH52	V_OPR_CH209	V_WPR_248	
V_GPR_CH59	V_OPR_CH221	V_WPR_249	
V_GPR_CH60	V_OPR_CH222	V_WPR_260	
V_GPR_CH68	V_OPR_CH226	V_WPR_359	
V_GPR_CH90H	V_OPR_CH249	V_WPR_CH100	
V_GPR_CH91H	V_OPR_CH29	V_WPR_CH117	
V_GPR_CH92H	V_OPR_CH31	V_WPR_CH119	
V_GPR_CH99	V_OPR_CH52	V_WPR_CH207	
V_GPR_CHSW06	V_OPR_CH59	V_WPR_CH208	
V_GPR_CHSW12	V_OPR_CH60	V_WPR_CH209	
V_GPR_CHSW125	V_OPR_CH68	V_WPR_CH221	
V_GPR_CHSW13	V_OPR_CH90H	V_WPR_CH222	
V_GPR_CHSW23	V_OPR_CH91H	V_WPR_CH226	
V_GPR_CHSW25	V_OPR_CH92H	V_WPR_CH249	
V_GPR_CHSW28	V_OPR_CH99	V_WPR_CH29	
V_GPR_CHSW30	V_OPR_CHSW06	V_WPR_CH31	
V_GPR_CHSW34	V_OPR_CHSW12	V_WPR_CH52	

NOTA: La letra V al inicio del nombre de cada variable indica que se trata de un vector respuesta


Anexo B. Flujo de trabajo.



El modelo integrado desarrollado parte de una base determinística proveniente del modelo de simulación, conformado por un modelo estático y dinámico preliminar, ubica las alternativas de desarrollo a nivel de subsuelo y las viste con todo lo referente a pozo, superficie, entrono, restricciones y habilitadores, así como el componente económico que rige a la organización pero migra de forma determinística dando como resultado un único perfil y una sola evaluación financiera.



A partir de allí se lleva a cabo una serie de formulaciones que permitan migrar de este caso a un modelo probabilístico que mediante distintas formas y algoritmos de optimización, probara las mejores alternativas que logren maximizar el valor presente neto del proyecto con un ciclo cerrado e iterativo.



Finalmente este modelo conectado a sistemas de redes neuronales de uso comercial, empieza a probar el mejor ajuste predictivo de perfiles y por ende aquellas variables que impactan negativamente la ejecución del proyecto, logrando a medida que recorre todo el espectro el mejor resultado.

Red Neuronal
Bases de datos numéricas

