



**Propuesta de un modelo de red neuronal artificial para optimizar el proceso
de selección de métodos de recobro mejorado de hidrocarburos
mediante microorganismos (MEOR)**

Elaborado por:
Bryan García Munévar

Directora:
Johanna Karina Solano

Universidad EAN
Escuela en Formación en Investigación
Proyecto de Integración
Bogotá
Junio de 2024



Tabla de Contenido

Resumen Ejecutivo	4
Introducción	5
Objetivos.....	6
Definición del problema	7
Justificación	9
Análisis de Requerimientos.....	11
Marco de Referencia.....	14
Análisis de Restricciones	24
Metodología y desarrollo de la solución	26
Análisis de Costos	36
Conclusiones	38
Referencias.....	40
Anexo A. Bases de Datos Recolectadas.....	48





Resumen Ejecutivo

La industria petrolera se enfrenta constantemente al desafío de maximizar la extracción de hidrocarburos de los yacimientos existentes. Para abordarlo, se han desarrollado diversos métodos de recuperación, entre los que destaca la recuperación mejorada de petróleo, conocida como EOR por sus siglas en inglés. Estos métodos avanzados ofrecen una oportunidad crucial para optimizar la producción y satisfacer la creciente demanda de energía, al tiempo que reducen la necesidad de nuevas exploraciones y los costos asociados.

Entre los métodos de EOR, la recuperación mejorada mediante microorganismos (MEOR) emerge como una alternativa prometedora, ofreciendo beneficios medioambientales y económicos significativos. Aunque menos aplicada que otras técnicas convencionales, el MEOR presenta un potencial considerable debido a su capacidad para mejorar la recuperación de petróleo con bajos costos y mínimas modificaciones en la infraestructura existente. No obstante, su implementación efectiva está sujeta a una comprensión profunda de las características específicas del yacimiento y a la selección adecuada de los microorganismos y técnicas apropiadas.

En este contexto, se busca desarrollar un modelo de red neuronal artificial que facilite la selección de métodos de recobro mejorado de hidrocarburos mediante microorganismos a partir de los múltiples casos de éxito. Este tipo de herramientas se presenta como una solución de diseño de ingeniería innovadora y eficaz, considerando la complejidad inherente de los yacimientos petroleros y resaltando el valor añadido que estas herramientas de inteligencia artificial pueden aportar al proceso de toma de decisiones en la industria petrolera



Introducción

Este documento describe el diseño de una red neuronal artificial que optimiza los procesos de selección de los métodos de recobro mejorado de hidrocarburos, también conocido como recobro terciario, mediante microorganismos. La red neuronal artificial se entrena a partir de casos de éxito alrededor del mundo donde las variables de entrenamiento estarán relacionadas con el tipo de fluidos que se encuentran en el yacimiento y las características de la formación.

Se seleccionan las variables de entrenamiento y estudio, así como los métodos de recobro mejorado mediante microorganismos (MEOR), de acuerdo con la disponibilidad de la información y la relevancia para el estudio. Posteriormente, se realiza la normalización y estandarización de la información para que esté lista para ser alimentada al modelo.

Posteriormente, se desarrolla el modelo de red neuronal artificial teniendo en cuenta la disponibilidad de herramientas y características técnicas requeridas para el contexto y variables seleccionadas.

Finalmente, se lleva a cabo el entrenamiento del modelo de red neuronal artificial con la información recopilada, y la ejecución de pruebas. Idealmente, este modelo podrá ser reentrenado si se cuenta con más información disponible, con el fin de refinar la precisión de la herramienta.



Objetivos

Objetivo General

Diseñar un modelo de red neuronal artificial para optimizar el proceso de selección de métodos de recobro mejorado de hidrocarburos mediante microorganismos (MEOR).

Objetivos Específicos

1. Definir la base de datos estándar de alimentación del modelo de red neuronal artificial a partir de aplicaciones exitosas de recuperación mejorada de petróleo mediante microorganismos (MEOR).
2. Elaborar el modelo de red neuronal artificial para la selección de métodos de recobro mejorado mediante microorganismos (MEOR).
3. Validar el modelo de red neuronal artificial de selección de métodos de recobro mejorado mediante microorganismos (MEOR) elaborado.



Definición del problema

La recuperación mejorada, conocida como EOR por sus siglas en inglés (Enhanced Oil Recovery), permite a la industria petrolera satisfacer la creciente demanda de hidrocarburos al maximizar la explotación de los yacimientos existentes. Además, reduce la necesidad de realizar nuevos descubrimientos y los costos asociados a estos. Sin embargo, los métodos de recuperación mejorada implican una mayor complejidad que otros tipos de recobro y representan un riesgo económico debido a su alta inversión. Entre estos métodos se encuentran la recuperación térmica, la combustión *in situ*, la inyección de polímeros, la recuperación mejorada mediante microorganismos (MEOR), entre otros.

El recobro mejorado mediante microorganismos (MEOR) presenta diversas ventajas, principalmente en términos ambientales y económicos. Sin embargo, su aplicación no es tan extendida debido a que su éxito está fuertemente condicionado por las características particulares del yacimiento, tales como la presión, temperatura, permeabilidad y porosidad, entre otros factores (Wu et al., 2022). Además, depende del crecimiento y metabolismo de los microorganismos, lo cual implica el análisis de variables de origen orgánico y genético (Amin et al., 2023), así como del método de implementación en el pozo seleccionado, ya sea mediante taponamiento selectivo, inundación o recuperación cíclica.

Varios estudios han desarrollado metodologías que emplean el aprendizaje automático (*machine learning*) para simplificar la selección de métodos convencionales de recobro mejorado EOR los cuales reducen los costos de experimentación y simulación, ofreciendo una precisión de predicción que alcanza valores de hasta el 94% (Prudencio, et al., 2022; Yasaman et al., 2023). Sin embargo, debido a la baja aplicación de métodos MEOR en



comparación con los métodos convencionales, a menudo son excluidos de los modelos o no proporcionan un análisis detallado sobre qué técnicas de MEOR podrían ofrecer mayores beneficios para el yacimiento en estudio.

Considerando el contexto mencionado, se evidencia la necesidad de desarrollar herramientas de selección mediante aprendizaje de máquina específicas para los métodos de recobro mejorado con microorganismos, que permitan hacer mas atractiva la implementación de estos métodos más económicos y sostenibles en la industria de los hidrocarburos.



Justificación

El uso de métodos MEOR destaca por su bajo impacto ambiental y costo reducido en comparación con otras técnicas de recobro mejorado: requieren menos modificaciones en la infraestructura y las instalaciones de pozo, consumen menos energía y la producción tanto de las bacterias como del medio nutriente se puede realizar a partir de materias primas económicas (Lourdes et al., 2022). Por tanto, representan una alternativa sustentable para la industria petrolera, cuyo único punto en contra es la alta dificultad de implementación, la cual radica en el gran número de variables relacionadas con los procesos metabólicos y orgánicos de los microorganismos y su interacción con el yacimiento.

Por tanto, el empleo de redes neuronales para facilitar la selección de las técnicas de implementación es particularmente conveniente, ya que estas destacan por su capacidad para generar modelos de predicción incluso con datos incompletos sin experimentar una pérdida de rendimiento considerable, y por su tolerancia a errores una vez completado el ciclo de aprendizaje (Maad, 2018). Así, las redes neuronales constituyen un excelente punto de partida para un método en el cual los registros de casos de éxito son limitados en comparación con otros métodos EOR.

En términos prácticos, el desarrollo de una red neuronal artificial para la selección de métodos de MEOR representa un ahorro de tiempo, esfuerzo y recursos para los operadores del recobro, al evitar pruebas de laboratorio y pruebas piloto extensivas antes de la implementación. Además, podría aumentar la preferencia por esta metodología al proporcionar una herramienta de selección específica para tal fin.



Desde un punto de vista teórico, la implementación de una red neuronal artificial brinda un valioso apoyo para comprender el mecanismo de interacción entre los microorganismos y el yacimiento. Además, permite analizar la relación entre diferentes variables y aplicar la teoría en la construcción de la red neuronal artificial, abordando aspectos clave de la inteligencia artificial, el aprendizaje profundo y modelos estructurales.

Finalmente, la aplicación de una red neuronal artificial facilita la gestión del conocimiento en este campo desde una perspectiva metodológica y aplicada en la ingeniería de sistemas, específicamente en el uso de inteligencia artificial para resolver problemas de la industria. Esto implica la aplicación de técnicas analíticas desarrolladas en el ámbito de la ingeniería, como la correlación de variables, la estadística y la creación de modelos artificiales.



Análisis de Requerimientos

Intención del proyecto: desarrollar un modelo de red neuronal artificial diseñado específicamente para optimizar el proceso de selección de métodos de recobro mejorado de hidrocarburos mediante microorganismos (MEOR). El modelo se utilizará como una herramienta de apoyo a la toma de decisiones para los ingenieros de yacimientos, proporcionando recomendaciones basadas en datos y análisis predictivos.

Verificación de parámetros de diseño: la red neuronal artificial debe ser capaz de ajustarse correctamente a los datos de entrenamiento y producir resultados con un grado de precisión evaluado al final de la convergencia de la red neuronal durante su entrenamiento y a través de un cotejo de la data. Se usará el 10% de los datos como data de prueba o de testeo y el restante como datos de entrenamiento.

Se diseñará una red neuronal con arquitectura de perceptrón multicapa, ya que su aprendizaje es adaptativo y se basa únicamente en el conjunto de datos dado, son aplicables a cualquier tipo de campo, en este caso el petrolero, y son usados especialmente para la discriminación y reconocimiento de patrones en datos que presenten relaciones lineales y no lineales (Park & Lek, 2016).

Para la determinación del número de neuronas ocultas, se tendrá en cuenta dos heurísticas conocidas, la primera de ellas indica que el número de neuronas ocultas debe ser $2/3$ el tamaño de la capa de entrada más el tamaño de la capa de salida. La segunda menciona que el número de neuronas debe ser igual o menor a dos veces el tamaño de la capa de entrada (Krishnan, 2021).



Como método de activación se usará la función rectificadora o “Relu”, la cual es una función que introduce la propiedad de no linealidad en un modelo de aprendizaje profundo y resuelve el problema de los gradientes de fuga y es una de las funciones de activación más populares en el aprendizaje profundo (Brownlee, 2020).

Se usará el método de activación “Softmax”, la cual transforma las salidas brutas de la red neuronal en un vector de probabilidades, de modo que devuelve un vector de salida para N entradas, en la que la entrada corresponde a la probabilidad de que esa entrada pertenezca a determinada clase. (Priya, s.f.)

Adicionalmente, para compilar la red neuronal se usará el algoritmo Adam, por sus siglas del inglés Adaptive Moment Estimation, el cual es un algoritmo de tasa de aprendizaje adaptativo diseñado para mejorar la velocidad de entrenamiento en redes neuronales profundas y alcanzar la convergencia con rapidez (Agarwal, 2023) y se asigna el modelo de pérdida como “categorical_crossentropy” teniendo en cuenta que serán tres o más los elementos a categorizar.

Estimación de ciertas características de diseño o especificaciones del producto: En esta etapa, se busca predecir y entender las características de modelo de red neuronal a desarrollar por lo que se incluye:

- **Eficiencia computacional:** se evaluará cuánto tiempo y recursos computacionales (como la memoria) consume el modelo durante el entrenamiento para entender si es práctico para usar en un entorno de producción real.
- **Robustez:** se determina la capacidad del modelo para manejar entradas de datos que pueden ser ligeramente diferentes a los datos de entrenamiento al



introducir pequeñas variaciones en los datos de prueba y viendo cómo afecta al rendimiento del modelo.

- **Generalización:** se refiere a qué tan bien puede hacer predicciones el modelo desarrollado sobre datos que no ha visto antes. Se evalúa mediante validación cruzada, dividiendo los datos en un conjunto de entrenamiento y un conjunto de prueba.
 - **Interpretabilidad:** el modelo no debe ser una “caja negra”, de modo que debe presentar descripciones claras para las personas que usen el modelo, entendiendo que ocurren en cada paso del proceso.
 - **Desempeño:** se evalúa el desempeño mediante la revisión de la precisión de la predicción en la etapa de convergencia de la red neuronal.



Marco de Referencia

La recuperación microbiana mejorada de petróleo (MEOR) es un importante enfoque de recuperación terciaria de petróleo que utiliza microorganismos y sus metabolitos, incluidos biosurfactantes, biopolímeros, ácidos biogénicos, enzimas, disolventes y biogases, para movilizar el petróleo residual de yacimiento (Niu et al., 2020). En este método de recobro, las bacterias se cultivan normalmente ex situ y luego se inyectan junto con agua en el yacimiento para que usen el hidrocarburo como fuente de energía para producir metabolitos. Los mecanismos de acción de éstos son reducir la viscosidad del crudo, aumentar la permeabilidad de la roca del yacimiento y disminuir las tensiones de interfase en las interfases petróleo/agua y petróleo/roca (Lourdes et al., 2022), de manera que se aumenta el recobro terciario en el yacimiento en el que es aplicado.

Según su aplicación, los procesos MEOR pueden clasificarse principalmente en cuatro tipos: recuperación microbiana por inundación (MFR), recuperación microbiana cíclica (CMR), recuperación microbiana por taponamiento selectivo (MSPR) y eliminación microbiana de la cera (MWR) (She et al., 2019). La recuperación microbiana por inundación o MFR (Microbial Flooding Recovery) es un mecanismo que aprovecha la inyección de agua y usa microorganismos como *Bacillus* y *Clostridium*, los cuales tienen mayor potencial de supervivencia en condiciones del yacimiento, ya que producen esporas. Se busca que los microorganismos se desplacen por la matriz del yacimiento, generen los metabolitos de interés, y se controle mediante la estrategia de inyección las velocidades relativas de transporte de nutrientes (Bryant et al., 1993). Por otra parte, la recuperación microbiana selectiva por taponamiento propone corregir las eficiencias de barrido microscópico y volumétrico dentro de las formaciones geológicas con altas variaciones de permeabilidad. Dado que las bacterias multiplican su masa exponencialmente, el taponamiento podría



aumentar y desviar el flujo hacia zonas menos permeables y aumentar la recuperación de petróleo en esas zonas (Raiders et al., 1989).

Otro de los procesos es la recuperación cíclica microbiana o CMR (Cyclic Microbial Recovery) en la cual se introduce una solución de microorganismos y nutrientes en un yacimiento de petróleo durante la inyección, posteriormente se cierra el pozo de inyección durante un periodo de incubación para que los microorganismos produzcan gas de dióxido de carbono (CO₂) y tensoactivos que ayuden a movilizar el petróleo. Finalmente, se abre el pozo y se extrae el petróleo y los productos resultantes del tratamiento (Patel et al., 2015). Por último, se encuentra la remoción de cera mediante microorganismos MWR (Microbial Wax Removal), en la cual se busca reducir la viscosidad para tratar el petróleo crudo ceroso a baja temperatura. Esto mejora considerablemente la fluidez del petróleo crudo, ya que los hidrocarburos de cadena larga se oxidan para generar alcoholes de cadena larga, los cuales se combinan con aldehídos de cadena media y se oxidan para formar ácidos grasos y otros compuestos de cadena corta (Wang et al., 2022). Sin embargo, la aplicabilidad de este método está reducida a ciertas zonas geográficas de Asia.

Existen otros métodos de MEOR más recientes, los cuales son el GEMEOR o Recuperación mejorada de petróleo mediante ingeniería genética microbiana el cual usa tecnologías como la recombinación, la fusión de protoplastos y la mutagénesis para concentrarse en las ventajas de diferentes cepas para construir bacterias de ingeniería, dándoles un mayor rendimiento de metabolitos y una mayor tolerancia que las bacterias ordinarias. (Ziwei et al., 2021); y el EEOR, que es recuperación de petróleo mediante enzimas la cual, como su nombre lo indica, usa tecnología enzimática para: alterar la humectabilidad agua-agua, rompiendo las conexiones entre las superficies de los granos y el petróleo; reducir la tensión interfacial, lo que afecta a las fuerzas capilares que actúan reteniendo parte del petróleo residual y, por último;



disminuyendo la viscosidad del petróleo mejorando su movilidad (Rahayyem et al., 2019). Sin embargo, no son incluidos en el presente estudio debido a la falta de información disponible sobre su aplicación.

Adicionalmente, es importante conocer qué propiedades o variables pueden afectar la viabilidad de los métodos MEOR. Las más básicas están relacionadas a las características del crudo y del yacimiento. La gravedad API, la viscosidad y la composición hacen parte de las propiedades del hidrocarburo; en cuanto al yacimiento se tiene en cuenta: Saturación de aceite, tipo de formación, espesor, permeabilidad, profundidad, temperatura (Taber et al., 1997). Adicionalmente, se sugiere tener en cuenta otras características relacionadas a la producción en particular, como lo es la evaluación de la historia de producción, la caracterización fisicoquímica del crudo y el análisis reológico (Segovia et al., 2009). Para evaluar rendimientos, se debe tener en cuenta características de la cinética microbiana, así como la combinación de cepas y nutrientes. Se estima que los parámetros cinéticos microbianos, operativos y de yacimiento influyen en la recuperación de petróleo en un 50%, 32,5% y 17,5%, respectivamente. (Pavan et al., 2022)

Teniendo en cuenta lo anterior, se hace evidente que la recuperación MEOR plantea una serie de dificultades en cuanto a la predicción de la producción. Además, ya que la cantidad de subproductos generados por los microorganismos también depende de las condiciones de crecimiento, como el pH, la salinidad y la temperatura, generar un modelo convencional se convierte en todo un reto (Hong et al., 2019). Variables que serán parametrizadas en una etapa posterior de este estudio.

Por este motivo, se sugiere la implementación de redes neuronales artificiales para facilitar la elección de los métodos MEOR. Es importante recordar que una neurona artificial es un modelo computacional que se inspira



en las neuronas biológicas. Estas últimas reciben señales mediante sinapsis localizadas en las dendritas o en la membrana neuronal. Si las señales recibidas son lo suficientemente intensas (es decir, superan un umbral específico), la neurona se activa y transmite una señal a través del axón. Esta señal puede ser enviada a otra sinapsis, activando así otras neuronas. (Gershenson, 2003). Una red neuronal artificial se puede construir simulando una red de neuronas modelo en una computadora. Mediante la aplicación de algoritmos que replican los procesos de las neuronas reales, podemos entrenar a la red para que “aprenda” a solucionar una variedad de problemas. A la neurona modelo se le conoce como unidad umbral. Recibe entradas de otras unidades o fuentes externas, sopesa cada entrada y las suma. Si la entrada total supera un umbral, la salida de la unidad es uno; de lo contrario, es cero (Krogh, 2008) y de esta manera va eligiendo los caminos más adecuados dentro del modelo.

En la arquitectura básica de una red neuronal, la capa más a la izquierda se denomina capa de entrada, y las neuronas que la componen, neuronas de entrada. La capa derecha o de salida contiene las neuronas de salida. La capa intermedia se denomina capa oculta, ya que las neuronas de esta capa no son ni de entrada ni de salida (Nielsen, 2015). Cada etapa de desarrollo de una red neuronal requiere un procedimiento de prueba y error para establecer una red estable para el proyecto. Esta metodología puede ser extendida para construir varias redes neuronales, y probarlas a diferentes etapas de aprendizaje e inicializarlas con diferentes pesos aleatorios (Rafiq et al., 2001), con el fin de aumentar la eficiencia y exactitud de la red.

Además, las redes neuronales emplean funciones de activación para realizar el cálculo de la suma ponderada de las entradas. Este cálculo es crucial para determinar si una neurona se activará. Estas funciones procesan los datos utilizando un método de gradiente, comúnmente el descenso de gradiente, y finalmente generan una salida para la red neuronal que incluye los parámetros



de los datos (Nwankpa et al., 2018). Cada función de activación se elige de acuerdo con la aplicación que se le va a dar a la red.

En general, las funciones de activación con una curva suave y continua pueden ayudar a la red a converger más rápidamente y obtener mejores resultados. Estas funciones también son adecuadas para tareas de clasificación binaria. Por otro lado, las funciones de activación con una curva más compleja o discontinua pueden ser más difíciles de optimizar, pero pueden ser más adecuadas para ciertos tipos de datos o tareas. Se utilizan a menudo en redes neuronales evolutivas para tareas de clasificación de imágenes, ya que son capaces de introducir la no linealidad y mejorar la capacidad de la red para capturar patrones complejos en los datos (Rodríguez P. & Buitrago R., 2022).

En relación con su aplicabilidad, las redes neuronales son sistemas capaces de modificar su estructura interna en relación con una función objetivo y son especialmente adecuadas para resolver problemas de tipo no lineal, ya que son capaces de reconstruir las reglas difusas que rigen la solución óptima de problemas (Grossi & Buscema, 2007). Para la realización de estudios complejos como la selección de métodos de recobro mejorado, en los que se desee usar todos los métodos de análisis disponibles requeriría, naturalmente, una gran cantidad de costes y un largo período de tiempo. En consecuencia, centrarse en algunos métodos concretos mediante el uso de redes neuronales sería muy beneficioso en términos de costes y tiempo y hará que el camino futuro esté más concentrado (Cheraghi et al., 2023), y viene a ser el objetivo principal del desarrollo de un modelo de redes neuronales artificiales.

En relación con el entrenamiento, la red necesita adquirir los pesos de conexión a partir de los patrones de entrenamiento existentes y la eficacia se incrementa con el tiempo mediante la actualización iterativa de los pesos de la red. Las redes neuronales parecen adquirir las reglas fundamentales (como las



relaciones de entrada y salida) a partir de un conjunto proporcionado de ejemplos representativos (Gupta, 2012). Así, el método de entrenamiento más efectivo implica reunir una variedad amplia de ejemplos que muestren todas las distintas características del problema. Para construir una red sólida y confiable, en ciertos casos se introduce cierto ruido o aleatoriedad a los datos de entrenamiento, permitiendo que la red se acostumbre al ruido y la variabilidad natural de los datos reales (Abraham, 2005), sin embargo esto debe ser ejecutado con una alta minuciosidad para no alterar por completo los resultados.

Las redes neuronales han sido aplicadas a la industria petrolera, especialmente a los procesos de recobro mejorado o terciario. A continuación una breve descripción de algunos casos disponibles en la literatura, resumidos en la Tabla 1

Tabla 1

Casos de aplicación de redes neuronales a la industria petrolera para recobro mejorado

Cita bibliográfica	Artículo	Resumen
(Sailaja & Kumari, 2021)	Aplicación de una red neuronal y lógica difusa para el análisis de proyectos MEOR	Se describe la aplicación de una red neuronal y lógica difusa para el análisis de proyectos MEOR EOR. Asociando explícitamente un patrón de conocimiento a los datos de campo, casos de éxito para procesos MEOR y datos de producción se realizó un modelo de red neuronal que predijo la recuperación de petróleo y permitió la realización de una prueba a



Cita bibliográfica	Artículo	Resumen
(Chavan et al., 2023)	Clasificación mediante aprendizaje automático para la selección de técnicas de recuperación mejorada de petróleo	<p>ciegas con un conjunto de datos de 125 casos de campo simulados con un error medio absoluto.</p> <p>Se recopiló una base de datos global de 358 proyectos EOR exitosos, de los cuales 176 se usaron en este estudio para entrenar redes neuronales (NN), máquinas de vectores de apoyo (SVM), K-Nearest Neighbor (KNN), Gaussian Naive Bayes y clasificadores Random Forest (RF), y se comprobó su eficacia. El resultado muestra que la técnica de clasificación RF predice el EOR más adecuado con un valor de precisión de 0,91, que es la precisión más alta entre todas las demás técnicas. El estudio también clasifica los parámetros del yacimiento y del fluido en función de su influencia en la selección de EOR. La viscosidad es el factor que más influye en la selección de una técnica de EOR, con una importancia del 34,6%.</p>



Cita bibliográfica	Artículo	Resumen
(Dhanarajan et al., 2017)	Recuperación microbiana mejorada de petróleo (MEOR) impulsada por biosurfactantes-biopolímeros y su optimización mediante una técnica híbrida ANN-GA	Se ensayó un biosurfactante lipopéptido producido por <i>Bacillus megaterium</i> marino y un biopolímero producido por <i>Bacillus licheniformis</i> termófilo para comprobar su potencial de aplicación en la recuperación mejorada de petróleo. La eficiencia de recuperación de petróleo de la solución de lipopéptido acondicionada con Ca^{2+} a partir de una columna con relleno de arena se optimizó mediante el uso de modelos de redes neuronales artificiales (RNA) junto con la optimización de algoritmos genéticos (AG).
(Alikhaniet al., 2014)	Predicción de la Recuperación Microbiana Mejorada de Petróleo utilizando un Inteligencia Artificial basado en datos experimentales	En este trabajo se utilizó una red neuronal multicapa. El número de neuronas de la capa oculta de la red se determinó mediante la evaluación del rendimiento. La red neuronal con 16 neuronas en la capa oculta tuvo el mejor rendimiento en todos los datos, por lo que se seleccionó y utilizó como modelo de red neuronal para



Cita bibliográfica	Artículo	Resumen
		predecir la recuperación de petróleo en 5 yacimientos.
(El-M Shokir et al., 2002)	Selección y evaluación del método EOR mediante inteligencia artificial	Se diseñó un modelo compuesto por dos redes neuronales que funcionan en serie para realizar la tarea de selección de proyectos EOR mediante la primera red (red técnica) y, a continuación, evaluar económicamente el proyecto seleccionado utilizando la segunda red (red económica). La red se entrena con 107 muestras y se prueba con 15 muestras. Esta red se entrenó con éxito para seleccionar entre cinco proyectos. A continuación, se aplicó a la red una prueba de ruido, y se comprobó que la red puede soportar hasta un 15% de ruido en los parámetros de entrada de nuestro modelo y seguir alcanzando una eficiencia del 100%.
(Nageh et al., 2015)	Aplicación usando lógica difusa como	Se desarrolla una técnica de inteligencia artificial mediante el



Cita bibliográfica	Artículo	Resumen
técnica de inteligencia artificial para la selección por criterios de las tecnologías EOR	uso de lógica difusa para modelar la selección de métodos EOR la cual se genera a partir de un análisis de las bases de datos disponibles al rededor del mundo, y permite ejecutar ejercicios de clasificación entre catorce métodos EOR.	



Análisis de Restricciones

Dentro de las restricciones técnicas se presenta la disponibilidad de la data para alimentar a la red neuronal artificial. En las bases de datos especializadas se encuentra información de libre acceso de la cual se puede extraer la información de casos de éxito de la aplicación de los métodos MEOR, sin embargo no en todos los casos se presenta de forma pública las propiedades del yacimiento y del fluido sobre las que se aplicaron las metodologías, limitando la data de alimentación.

Las restricciones relacionadas al costo del software no se evidencian, ya que se usará Tensor Flow el cual es una biblioteca de código abierto gratuita enfocada al aprendizaje automático y la inteligencia artificial. Así mismo, este software se ejecuta mediante una aplicación web, de modo que se puede correr en cualquier navegador web, disminuyendo los requisitos técnicos del equipo de cómputo a utilizar.

No se evidencian restricciones de tipo ambiental, más allá del consumo de energía del equipo de computo en donde se ejecute la red neuronal artificial. Como se menciona anteriormente, al ser desarrollada en una aplicación web, no se espera un impacto considerable.

Dentro de las restricciones legales, no se evidencia ninguna ya que la alimentación de la red neuronal se realiza mediante la información disponible en las bases de datos académicas. Para usos de tipo privado, el ejecutor del entrenamiento de esta red estará encargado de conseguir el material de alimentación, ya sea propio o externo, dentro de las normativas legales que le apliquen por privacidad de la información.



No se evidencian restricciones de salud y seguridad. En cuanto a las restricciones socioculturales, no se identifica una afectación a los profesionales de la ingeniería de petróleos o afines al desarrollo de la evaluación de selección de métodos EOR, ya que la herramienta solo facilita este paso mencionado, pero no reemplaza la labor de evaluación, implementación y/o pruebas adicionales que se requieran para la aplicación de los métodos MEOR.



Metodología y desarrollo de la solución

Para la correspondiente investigación, se realiza un proyecto con un enfoque cuantitativo. En este caso, la investigación se centra en el análisis de datos relacionados con el proceso MEOR, como propiedades geológicas, datos operativos, condiciones de campo, y otros factores cuantitativos que influyen en la selección del método MEOR óptimo. El desarrollo y la optimización de un modelo de redes neuronales implican la manipulación de datos numéricos y la aplicación de algoritmos cuantitativos para entrenar y evaluar el rendimiento del modelo.

El alcance de la investigación es de tipo correlacional, ya que el modelo se construirá para establecer relaciones y posiblemente identificar causas y efectos entre las variables seleccionadas. Se buscarán patrones en los datos que permitan predecir el método MEOR óptimo en función de las variables de entrada.

Se considera un diseño no experimental y transversal, ya que no hay manipulación de las variables e implica la recopilación de datos en un momento específico o para su análisis. Se recopilan datos históricos y actuales relacionados con el proceso MEOR, pero no se sigue un seguimiento continuo a lo largo del tiempo.

La selección de la muestra se realiza de forma dirigida o no probabilística, ya que se obtendrán datos secundarios de otras investigaciones y/o artículos científicos publicados de casos de éxito de proyectos de recobro MEOR. La población en este proyecto consiste en todos los artículos científicos relacionados con el proceso MEOR y la selección de métodos MEOR que están disponibles en fuentes académicas y científicas. Esta población puede ser muy amplia y diversa, ya que puede incluir investigaciones publicadas en revistas científicas, conferencias, tesis doctorales, informes técnicos, y otras fuentes académicas.



Se debe seleccionar una muestra representativa que sea lo suficientemente grande como para proporcionar datos significativos, pero manejable para el análisis. El proceso de selección de la muestra se realizará a conveniencia por tres razones:

- **Disponibilidad de datos:** Los artículos científicos suelen estar disponibles en línea o a través de recursos académicos, sin embargo no siempre se publica la totalidad de los datos que se usaron para el proceso MEOR. Utilizar un muestreo por conveniencia permite aprovechar la disponibilidad de la información.
- **Recursos limitados:** Por términos de tiempo y recursos humanos que se invierten en esta investigación, no resulta práctico realizar un método de muestreo estadístico.
- **Enfoque en la investigación:** La selección de artículos científicos basada en la relevancia y la calidad de la investigación puede ser preferible. Algunos artículos pueden ser más relevantes que otros para los objetivos específicos de la investigación, y el muestreo por conveniencia permite centrarse en aquellos que mejor se ajusten a esos objetivos.

Principalmente se recolectarán datos secundarios de investigación derivados de artículos científicos, de manera que se seguirá un procedimiento sistemático describe a continuación:

- **Definición de criterios de inclusión y exclusión:** Se tendrá en cuenta la información recopilada a partir de artículos científicos,



conferencias, tesis, informes técnicos y otras fuentes con validez académica y científica.

- **Búsqueda bibliográfica:** Se realizarán búsquedas sistemáticas en bases de datos académicas y motores de búsqueda académica para identificar artículos que cumplan con los criterios de inclusión.
- **Muestreo a conveniencia:** A priori se estima que la cantidad de información disponible no va a ser lo suficientemente grande para ajustarlo a un método estadístico, de manera que se usará la información disponible y pertinente.
- **Tamaño de la muestra:** Dependerá de la cantidad de información disponible en las bases de datos, pero se buscará que sea lo suficientemente representativa para realizar el análisis mediante redes neuronales.

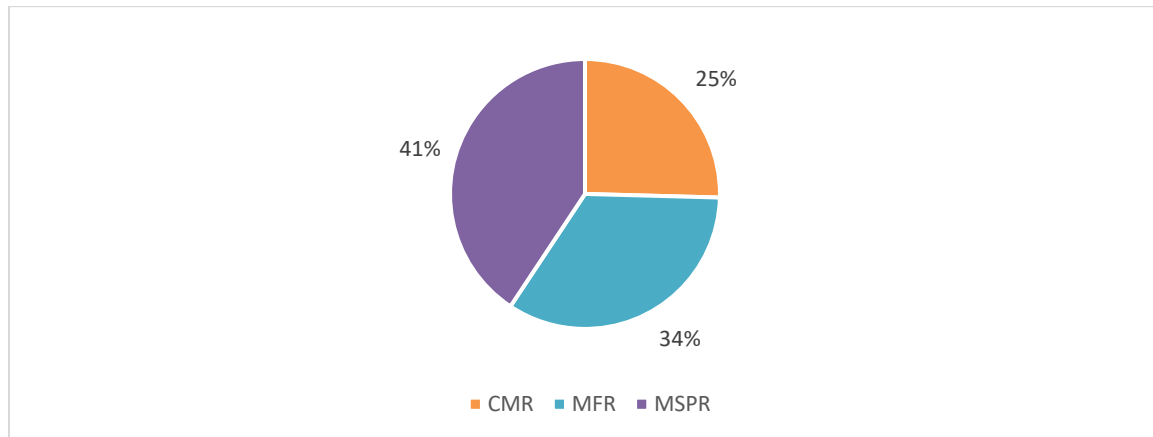
Teniendo en cuenta eso, se recopila la información a partir de bases de datos académicas y se encontró información para tres métodos de recobro mejorado mediante microorganismos: CMR (Cyclic Microbial Recovery), MFR (Microbial Flooding Recovery) y MSPR (Microbial Selective Plugging Recovery), distribuidos como se muestra en la Figura 1 y en el Anexo A. El método MWR no presenta información suficiente en las bases de datos por lo que es descartado de la investigación.

En cuanto a las variables seleccionadas para cada uno de los métodos se cuenta con el tipo de formación, la profundidad, la permeabilidad efectiva, la temperatura de fondo de pozo, la gravedad API, la viscosidad y la porosidad.



Figura 1

Distribución de los tipos de MEOR seleccionados para el análisis



En cuanto a la composición, el espesor de la formación y la saturación, no se contó con suficiente data, de manera que se excluyó del modelo. Por convención, todas las variables se expresan en unidades inglesas de acuerdo con el estándar de la industria. Se realiza un análisis estadístico de la muestra, el cual se resume en la Tabla 2.

Tabla 2

Análisis estadístico de las variables seleccionadas

Parámetro Estadístico	Profundidad (ft)	Permeabilidad Efectiva (mD)	Temperatura (°F)	Gravedad API (°API)	Viscosidad (cP)	Porosidad (%)
Media	3892.14	516.16	125.92	25.5	77.69	23
Mediana	3927	300	122	23	12	23
Moda	3927	84.00 ^a	68.00 ^a	22.00 ^a	2.5	15.00 ^a
Desv. estándar	2032.88	650.71	35.97	7.34	267.46	6.1
Varianza	4132580.92	423418.06	1294.19	53.8	71533.15	37.2



Parámetro Estadístico	Profundidad (ft)	Permeabilidad Efectiva (mD)	Temperatura (°F)	Gravedad API (°API)	Viscosidad (cP)	Porosidad (%)
Asimetría	0.15	3.17	0.23	0.56	5.13	0
Error estándar de asimetría	0.35	0.31	0.32	0.34	0.44	0.37
Mínimo	341.12	1.7	68	13.99	2	12.8
Máximo	8647	4000	208	42.55	1429	33

^a Existen múltiples modas, se muestra el valor más pequeño.

Como se consideró que la viscosidad era un parámetro de interés para la presente investigación, se complementaron los datos mediante el uso de correlaciones para el cálculo de esta propiedad, para este caso se usó la correlación de Beal y la de Beggs y Robinson. (Beal, 1946) (Beggs & Robinson, 1975).

Adicionalmente, se debe considerar que el núcleo del proyecto es la creación de la red neuronal, que funciona como instrumento de investigación al permitir la modelación y análisis de datos complejos. Su capacidad para identificar patrones, relaciones y tendencias ocultas en datos multidimensionales proporciona una base sólida para la toma de decisiones basada en evidencia, lo que contribuye significativamente a la robustez y la validez de la investigación.

Por lo cual, se integra en un notebook de Jupiter para realizar la red neuronal a través de la librería Numpy de Python, Pandas y Tensor Flow. Para el presente desarrollo se usó la versión 2.14 de Tensor Flow. El desarrollo y ejecución de la red neuronal se puede observar en el siguiente enlace: https://colab.research.google.com/drive/1rAkCmKOc4-bjPI4Hq_hITf63TgULA6JW?usp=sharing



Para el desarrollo de la red neuronal artificial, se tendrán en cuenta los parámetros definidos en el análisis de requerimientos, en los que se incluye la arquitectura, el número de neuronas ocultas y los algoritmos a utilizar, por conveniencia teórica.

Como primer paso, se realiza el preprocesamiento de la información a partir del set de datos ajustado con las correlaciones de viscosidad en formato csv, seleccionando como data de entrada las columnas correspondientes a las variables, y la variable de respuesta el tipo de mecanismo de MEOR utilizado. La variable de respuesta se integró a partir de tres columnas diferentes, una para cada mecanismo, a la que se le otorgaron valores binarios (cero y uno). Para la variable "Formación" al ser una variable categórica, se codifica mediante la función Label Encoder, en la que se le asignaron valores numéricos a cada uno de los tipos de formación.

Una vez lista la data, se procede a separar el dataset en datos de entrenamiento y datos de prueba. Debido a la cantidad de datos considerablemente bajo, se determina el 10% para la data de pruebas, teniendo en cuenta que el estándar es el 20%. Para el escalado de la función, se hace uso de la función `sc.fit_transform`. Esto teniendo en cuenta que la estandarización de datos es el proceso de reescalado de los atributos para que tengan media 0 y varianza 1, el cual busca reducir todas las características a una escala común sin distorsionar las diferencias en el rango de los valores. (Khanna, 2020).

Como segundo paso, se inicializa la red neuronal desde la librería Keras integrada en Tensor Flow y se crea la capa de entrada y la primera capa de la red neuronal usando la clase de capa densa. Una capa densa es un conjunto de neuronas, cada una de las cuales se conecta a todas las neuronas de la capa anterior. El término "densa" se refiere a la densidad de conexión de cada



neurona con todas las neuronas de la capa anterior. (Educative Inc., 2023). Para la primera capa oculta, se seleccionó un total de 12 neuronas seleccionando un valor intermedio de las dos heurísticas definidas en el análisis de requerimientos, mientras que las neuronas de la capa de entrada, será el número de parámetros.

Como se definió en la etapa de análisis de requerimientos, se usa la función rectificadora o “Relu”, y se establece para la capa de salida tres unidades, una para cada uno de los métodos de MEOR seleccionados para el análisis, y se usa el método de activación “Softmax” y el algoritmo de compilación Adam.

Pasando al entrenamiento de la red neuronal, se selecciona el método por batches, seleccionado el tamaño del bache en 32, con 100 épocas. Los resultados del entrenamiento se pueden detallar a continuación (se muestran solo 10 épocas) en la Tabla 3.

Tabla 3

Épocas de entrenamiento de la red neuronal

Época	Tiempo	Pérdida	Precisión
1/100	1s 18ms/step	1.1323	0.2750
10/100	0s 8ms/step	1.0790	0.3750
20/100	0s 9ms/step	1.0348	0.4500
30/100	0s 9ms/step	1.0008	0.4500
40/100	0s 12ms/step	0.9673	0.5250
50/100	0s 9ms/step	0.9335	0.5500
60/100	0s 8ms/step	0.9003	0.5250
70/100	0s 8ms/step	0.8642	0.6750
80/100	0s 9ms/step	0.8259	0.6750
90/100	0s 8ms/step	0.7856	0.7000
100/100	0s 8ms/step	0.7465	0.6750

A partir de esto, se detalla que hubo una convergencia con una precisión de 67.5 % para la clasificación de los modelos. Posteriormente, se realizó una



evaluación de todo el set, para confirmar la viabilidad del modelo, el cual se detalla en la Tabla 4.

Tabla 4.

Validación del entrenamiento

Muestra	Tipo de MEOR (real)	CMR (red neuronal)	MFR (red neuronal)	MSPR (red neuronal)	Coincide
1	CMR	32.9%	42.0%	25.1%	No
2	CMR	33.7%	44.7%	21.6%	No
3	CMR	35.7%	41.2%	23.1%	No
4	MFR	30.2%	44.1%	25.7%	Si
5	MFR	32.8%	43.1%	24.1%	Si
6	MFR	16.2%	55.5%	28.2%	Si
7	MFR	20.4%	51.1%	28.5%	Si
8	MFR	9.8%	71.4%	18.8%	Si
9	MFR	8.1%	74.8%	17.1%	Si
10	MFR	18.9%	51.4%	29.7%	Si
11	MFR	21.2%	54.3%	24.5%	Si
12	MFR	21.9%	52.4%	25.7%	Si
13	MFR	39.0%	43.1%	18.0%	Si
14	MFR	59.5%	22.0%	18.5%	No
15	MFR	15.3%	59.0%	25.6%	Si
16	MFR	27.8%	43.0%	29.3%	Si
17	MFR	33.0%	36.6%	30.4%	Si
18	MFR	19.6%	58.6%	21.8%	Si
19	MFR	29.1%	45.2%	25.6%	Si
20	CMR	52.8%	19.6%	27.6%	Si
21	CMR	53.5%	24.1%	22.4%	Si
22	CMR	57.0%	23.6%	19.3%	Si
23	MFR	13.1%	58.5%	28.4%	Si
24	MFR	35.3%	42.9%	21.9%	Si
25	MFR	12.6%	65.5%	21.9%	Si
26	MFR	33.4%	35.8%	30.7%	Si
27	MSPR	13.9%	53.3%	32.7%	No
28	MSPR	19.1%	57.7%	23.2%	No
29	MSPR	33.6%	25.5%	40.9%	Si
30	MSPR	40.3%	17.9%	41.8%	Si
31	MSPR	39.8%	38.4%	21.8%	No
32	MSPR	39.3%	32.6%	28.0%	No



Muestra	Tipo de MEOR (real)	CMR (red neuronal)	MFR (red neuronal)	MSPR (red neuronal)	Coincide
33	MSPR	31.1%	20.7%	48.2%	Si
34	MSPR	26.1%	47.6%	26.3%	No
35	MSPR	29.1%	43.2%	27.6%	No
36	MSPR	69.0%	9.6%	21.4%	No
37	MSPR	24.7%	40.7%	34.6%	No
38	MSPR	30.4%	25.4%	44.3%	Si
39	MSPR	30.3%	28.0%	41.6%	Si
40	CMR	55.8%	19.3%	24.9%	Si
41	CMR	69.9%	10.3%	19.9%	Si
42	CMR	48.3%	31.7%	20.0%	Si
43	CMR	58.6%	6.4%	35.0%	Si
44	CMR	58.8%	11.4%	29.8%	Si
45	CMR	98.2%	0.7%	1.1%	Si

A partir de los datos, se evidencia que el modelo predijo correctamente el 73% de las veces, lo cual es mayor que la precisión arrojada por el modelo (67.5%). Cabe aclarar, que para mejorar la exactitud del modelo y la confiabilidad en este, idealmente, se debe contar con 10 veces la información como el número de parámetros del modelo o grados de libertad (Dorfman, 2022). Para el modelo, se contaba con siete grados de libertad o siete parámetros por lo que se esperaba tener mínimo 70 datos, por lo que se estima que la calidad de la red creada mejore a medida que se cuente con más datos. Para el presente proyecto, se realizó según disponibilidad de las fuentes bibliográficas y se recurrió a correlaciones para completar algunos datos faltantes de viscosidad, de modo que la escalabilidad del modelo favorecerá su precisión.

Se detallan casos en donde la red efectivamente encuentra el tipo de MEOR a realizar, pero con un porcentaje de probabilidad relativamente bajo, o en las ocasiones otro de los métodos obtiene un valor mayor, pero el siguiente más alto es la opción correcta, esto se debe al uso del método Softmax y el uso de estas herramientas para la clasificación de variables, ya que para tareas que



implican una elección entre opciones discretas, se suele considerar que el valor de la salida más alta representa la confianza de la red o la estimación de la probabilidad de que la clase correspondiente sea correcta, sin embargo, no está claro que esta interpretación esté justificada. (DeChant et al., 2019).



Análisis de Costos

En cuanto al análisis de costos del proyecto desarrollado se desglosan los costos directos en la Tabla 5, todos los valores expresados en pesos colombianos. No se detallan costos del uso de software, ya que se realiza mediante librerías y herramientas gratuitas de la suite de Google.

Tabla 5

Costos directos del proyecto

Nombre	Descripción	Frecuencia	Precio Unitario	Total
Equipo de Computo	Portátil Intel Core i5 - RAM 12GB - Disco SSD 512GB	1	\$,3799,000	\$ 3,799,000
Servicio de Internet	Conexión	1	\$200,000	\$ 200,000
Costo de Ingeniería	40h de ingeniería Senior	80	\$150,000	\$ 12,000,000
				\$ 15,999,000

Para los costos fijos, se presenta en la Tabla 6, todos los valores expresados en pesos colombianos.

Tabla 6

Costos fijos del proyecto

Nombre	Descripción	Precio Mensual	Total Anual
Energía	Uso continuado 1,2 kWh/dia	\$ 38,628.00	\$ 463,536.00
Internet	Mensual	\$ 120,000.00	\$ 1,440,000.00
			\$ 1,903,536.00



Para el análisis del caso de negocio, se asumen como beneficios económicos la reducción en el costo de un piloto para implementación de un proyecto MEOR, estimado en un 4% del valor total del piloto. Se toma como base el caso de implementación MEOR en el campo Vizcacheras en Argentina (Strappa et al., 2004), el cual presenta un costo de 2.8USD por cada barril extraído durante el 2000 y el 2003. Teniendo en cuenta el efecto de la inflación, este valor a precios del 2024 corresponde a 5.4 USD. En total se alcanzó una recuperación incremental de 37000 barriles de aceite. Teniendo en cuenta esto, el costo de pruebas para selección de MEOR se estima en 0.216 USD por barril extraído.

Para el total de 3 años, se asume tasa constante de extracción de petróleo, siendo 1027,77 BBL/mes; representando un costo mensual de 222 USD/mes en ahorros gracias a esta implementación, que con una TRM a día 28 de Mayo de 2024, representa \$860,931.54 pesos colombianos por mes, \$10,331,178.48 anuales.

Se hace el análisis de la tasa interna de retorno como se muestra en la Tabla 7, y se evidencia una TIR del 26.90% para el caso de estudio seleccionado a 3 años.

Tabla 7

Flujo de Caja del proyecto y evaluación de la TIR

Año	Flujo de Caja
AÑO 0	-\$ 15,999,000.00
AÑO 1	\$ 8,427,642.48
AÑO 2	\$ 8,427,642.48
AÑO 3	\$ 8,427,642.48
TIR	26.90%



Conclusiones

Se realiza el desarrollo de una red neuronal artificial para la predicción del método más adecuado para recuperación mejorada de petróleo mediante microorganismos o MEOR, entre tres técnicas conocidas como CMR (Cyclic Microbial Recovery), MFR (Microbial Flooding Recovery) y MSFR (Microbial Selective Plugging Recovery). Se entrena la red neuronal a partir de datos de 45 casos de éxito de aplicación de MEOR que contaran con los parámetros definidos para el modelo: tipo de formación geológica, la profundidad del yacimiento, la permeabilidad efectiva, la temperatura, la gravedad API, la viscosidad y la porosidad.

La red neuronal se realiza en un notebook de Jupyter disponible en https://colab.research.google.com/drive/1rAkCmKOc4-bjPl4Hq_hITf63TgULA6JW?usp=sharing, a través de Tensor Flow y las librerías de Keras. La función de activación usada fue “Relu”, y el método de activación fue “Softmax”. El algoritmo de aprendizaje fue Adam y el modelo de pérdida fue de entropía cruzada categórica evaluando como única métrica la precisión. Fue entrenada en batches de tamaño 32 y ejecutada en 100 épocas.

La red neuronal desarrollada cuenta con 12 neuronas en la capa oculta, 7 neuronas en la capa de entrada (correspondientes a las 7 variables mencionadas) y 3 de salida, las cuales representan cada una de las metodologías de aplicación de los métodos MEOR. El modelo brindó una precisión esperada del 67.5%, que luego se comprobó con los datos iniciales resultando en un 73% de precisión para la selección del método. Se espera que una base de datos más amplia mejore la precisión del modelo después de reentrenarlo.



El análisis de costos se hace teniendo en cuenta un caso de aplicación real, en el que se calcula una tasa interna de retorno del 26.9% para tres años de aplicación de la prueba piloto.



Referencias

- Abraham, A. (2005). *Artificial neural networks. Handbook of measuring system design*. Stillwater, OK, USA: Oklahoma State University. Fonte: Handbook of measuring system design.
- Agarwal, R. (2023, 13 de Septiembre). Complete Guide to the Adam Optimization Algorithm. Obtenido de <https://builtin.com/machine-learning/adam-optimization>
- Akintunji, F., Marcotte, B., Sheehy, A., & Govreau, B. (2012). A Texas MEOR Application Shows Outstanding Production Improvement Due To Oil Release Effects On Relative Permeability. *SPE Improved Oil Recovery Symposium*. Tulsa, Oklahoma. doi:<https://doi.org/10.2118/154216-MS>
- Alikhani, P., Mohammadreza, S., & Hashemi, A. (2014). Prediction of Microbial Enhanced Oil Recovery using an Artificial Intelligence Method based on Experimental Data. *International Journal of Computer Applications*, 975, 8887.
- Ariadji, T., Astuti, D. I., Aditiawati, P., Purwasena, I., Persada, G., Soeparmono, M. R., . . . Aditya, G. (2017). Microbial Huff and Puff Project at Mangunjaya Field Wells: The First in Indonesia Towards Successful MEOR Implementation. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. Jakarta, Indonesia. doi:<https://doi.org/10.2118/186361-MS>
- Ariadji, T., Astuti, D. I., Priharto, N., Ananggadipa, A. A., Persada, G. P., Subiantoro, E., & Erwanto, P. E. (2019). Field Implementation of Nutrient Huff and Puff in Bentayan Field, South Sumatera: Towards a Low-Cost EOR. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. Bali, Indonesia. doi:<https://doi.org/10.2118/196536-MS>



- Amin, B., Alireza, K., & Mohammad, A. (2023). An insight into the microorganism growth prediction by means of machine learning approaches. *Journal of Petroleum Science and Engineering, Volume 220*(Part A).
- Beal, C. (1946). The Viscosity of Air, Water, Natural Gas, Crude Oils and Its Associated Gasses at Oil-Field Temperatures and Pressures. *Trans, AIME*, 165, 94-115.
- Beggs, H., & Robinson, J. (1975). Estimating the Viscosity of Crude Oil Systems. *J. Pet. Tech. Forum*, 1140-1141.
- Bryant, R. S., Stepp, A. K., Bertus, K. M., Burchfield, T. E., & Dennis, M. (1994). Microbial Enhanced Waterflooding Field Tests. *SPE/DOE Improved Oil Recovery Symposium*, Tulsa, Oklahoma. doi:<https://doi.org/10.2118/27751-MS>
- Bryant, R., Stepp, A., Bertus, K. M., Burchfielda, T., & Dennisb, M. (1993). Microbial-Enhanced Waterflooding Field Pilots. *Developments in Petroleum Science, Volume 39*, 289-306.
- Brownlee, J. (2020, 20 de Agosto). A Gentle Introduction to the Rectified Linear Unit (ReLU). Obtenido de <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>
- Budiharjo, H., Suhascaryo, N., Nugroho, H. A., & Saputra, B. A. (2017). Optimizing oil recovery through microbial injection to support the increasing demand for oil in Indonesia. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. doi:<https://doi.org/10.2118/186214-MS>
- Chavan, H. K., Sinharay, R. K., Kumar, V., & Patel, D. (2023). An approach of using machine learning classification for screening of enhanced oil recovery techniques. *Petroleum Science and Technology*, 1-19.
- Cheraghi, Y., Kord, S., & Mashayekhizadeh, V. (2023). A two-stage screening framework for enhanced oil recovery methods, using artificial neural networks. *Neural Computing and Applications*, 1-18.



- DeChant, C., Han, S., & Lipson, H. (2019). Predicting the accuracy of neural networks from final and intermediate layer outputs. *ICML 2019 Workshop on Identifying and Understanding Deep Learning Phenomena*.
- Dhanarajan, G., Rangarajan, V., Bandi, C., Dixit, A., Das, S., Ale, K., & Sen, R. (2017). Biosurfactant-biopolymer driven microbial enhanced oil recovery (MEOR) and its optimization by an ANN-GA hybrid technique. *Journal of biotechnology*, 256, 46-56.
- Dietrich, F. L., Brown, F. G., Zhou, Z. H., & Maure, M. A. (1996). Microbial EOR technology advancement: case studies of successful projects. *SPE Annual Technical Conference and Exhibition*, (págs. SPE-36746). Denver, Colorado. doi:<https://doi.org/10.2118/36746-MS>
- Dorfman, E. (25 de Marzo de 2022). *How Much Data Is Required for Machine Learning?* Obtenido de <https://postindustria.com/how-much-data-is-required-for-machine-learning/>
- Educative Inc. (2023). *Keras dense layer*. Obtenido de <https://www.educative.io/answers/keras-dense-layer>
- El-M Shokir, E. M., Goda, H. M., Sayyouh, M. H., & Fattah, K. A. (2002). Selection and Evaluation EOR Method Using Artificial Intelligence. *Paper presented at the Annual International Conference and Exhibition, Abuja, Nigeria, August 2002*.
- Feng, Q. X. (2012). Application of a Novel Amylum-Cellulose Nutrient System for Microbial Flooding in Dagang Oilfield, China. *SPE Improved Oil Recovery Symposium*. Tulsa, Oklahoma. doi:<https://doi.org/10.2118/150501-MS>
- Feng, Q. X., Ni, F. T., Qin, B. Y., Ma, X. P., Ji, C. F., & Wang, X. L. (2006). Review of MEOR Technology Application in Dagang Oilfield for the Last Decade. *SPE Asia Pacific Oil & Gas Conference and Exhibition*. doi:<https://doi.org/10.2118/100791-MS>
- Gershenson, C. (2003). Artificial neural networks for beginners. *arXiv preprint cs/0308031*.



- Grossi, E., & Buscema, M. (2007). Introduction to artificial neural networks. *European journal of gastroenterology & hepatology*, 19(12), 1046-1054.
- Gupta, N. (2012). Artificial neural network. *Network and Complex Systems*, 24-28.
- Hong, E., Jeong, M. S., Kim, T. H., Lee, J. H., Cho, J. H., & Lee, K. S. (2019). Development of coupled biokinetic and thermal model to optimize cold-water microbial enhanced oil recovery (MEOR) in homogenous reservoir. *Sustainability*, 11(6), 1652.
- Ibragimov, K. M., Abdullayeva, F., & Guseynova., a. N. (2015). Experience of Microbial Enhanced Oil Recovery Methods At Azerbaijan Fields. *SPE Annual Caspian Technical Conference & Exhibition*. Baku, Azerbaijan. doi:<https://doi.org/10.2118/177377-MS>
- Ivanov, M. V., Belyaev, S. S., Borzenkov, I. A., Glumov, I. F., & Ibatullin, R. R. (1993). Additional oil production during field trials in Russia. *Developments in Petroleum Science*, 39, 373-381. doi:[https://doi.org/10.1016/S0376-7361\(09\)70074-3](https://doi.org/10.1016/S0376-7361(09)70074-3)
- Khanna, C. (25 de Agosto de 2020). *What and why behind fit_transform() and transform() in scikit-learn!* Obtenido de <https://towardsdatascience.com/what-and-why-behind-fit-transform-vs-transform-in-scikit-learn-78f915cf96fe>
- Krishnan, S. (2021, Septiembre 8). How do determine the number of layers and neurons in the hidden layer? Obtenido de <https://medium.com/geekculture/introduction-to-neural-network-2f8b8221fbd3>
- Krogh, A. (2008). What are artificial neural networks? *Nat Biotechnol*, 26, 195-197.
- Lourdes, R. S., Cheng, S. Y., Chew, K. W., Ma, Z., & Show, P. L. (2022). Prospects of microbial enhanced oil recovery: Mechanisms and environmental sustainability. *Sustainable Energy Technologies and Assessments, Volume 53*(Part B).



- Maad, M. (2018). *Artificial Neural Networks Advantages and Disadvantages*. Retrieved from LinkedIn: <https://www.linkedin.com/pulse/artificial-neural-networks-advantages-disadvantages-maad-m-mijwel>
- Maure, A., Saldaña, A. A., & Juarez., A. R. (2005). Biotechnology Applications to EOR in Talara Off-shore Oil Fields, Northwest Peru. *SPE Latin American and Caribbean Petroleum Engineering Conference*. Rio de Janeiro, Brazil. doi:<https://doi.org/10.2118/94934-MS>
- Nageh, M., El Ela, M. A., El Tayeb, E. S., & Sayyoub, H. (2015). Application of using fuzzy logic as an artificial intelligence technique in the screening criteria of the EOR technologies. *SPE North Africa Technical Conference and Exhibition*.
- Nazina T, S. D., Semenova, E., Babich, T., Bidzhieva, S., Serdukov, D., Volkov, D., . . . Ershov, A. (2020). The Potential Application of Microorganisms for Sustainable Petroleum Recovery from Heavy Oil Reservoirs. *Sustainability*. 2020, 12(1), 15. doi:<https://doi.org/10.3390/su12010015>
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA: Determination press.
- Niu, J., Liu, Q., Lv, J., & Peng, B. (2020). Review on microbial enhanced oil recovery: Mechanisms, modeling and field trials. *Journal of Petroleum Science and Engineering*, 192.
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). ctivation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint*.
- Park, Y. S., & Lek, S. (2016). Artificial neural networks: Multilayer perceptron for ecological modeling. In *Developments in environmental modelling* (Vol. 28, pp. 123-140). Elsevier
- Patel, J., Borgohain, S., Kumar, M., Rangarajan, V., & Somasundaran. (2015). Recent developments in microbial enhanced oil recovery. *Renewable and Sustainable Energy Reviews*, 52, 1539–1558.



- Pavan, P. S., Arvind, K., Nikhil, B., & Sivasankar, P. (2022). Predicting performance of in-situ microbial enhanced oil recovery process and screening of suitable microbe-nutrient combination from limited experimental data using physics informed machine learning approach. *Bioresource Technology*, 351.
- Priya, B. (s.f.). Softmax Activation Function: Everything You Need to Know. Obtenido de Pinecone Systems, Inc.: <https://www.pinecone.io/learn/softmax-activation/>
- Prudencio, G., Celis, C., Armacanqui, J., & Sinchitullo, J. (2022). Development of an evolutionary artificial neural network-based tool for selecting suitable enhanced oil recovery methods. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 44, 121.
- Rafiq, M. Y., Bugmann, G., & Easterbrook, D. J. (2001). Neural network design for engineering applications. *Computers & Structures*, 79(17), 1541-1552.
- Raiders, R., Knapp, R., & McInerney, M. (1989). Microbial selective plugging and enhanced oil recovery . *Journal of Industrial Microbiolog*, 215-230.
- Rodríguez P., A. I., & Buitrago R., X. D. (2022). How to choose an activation function for deep learning. *Tekhnê*, 19(1), 23–32.
- Sabut, B., Salim, M. A., Hamid, A. S., & Khor., S. F. (2003). Further Evaluation of Microbial Treatment Technology for Improved Oil Production in Bokor Field, Sarawak. *SPE International Improved Oil Recovery Conference in Asia Pacific*. Kuala Lumpur, Malaysia. doi:<https://doi.org/10.2118/84867-MS>
- Sailaja, P., & Kumari, P. L. (2021). Intelligence of AI in MEOR Process. *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)*, 1678-1685.
- Segovia, G. C., Huerta, V. A., & Guitierrez, G. C. (2009). Improving MEOR performance by a selection methodology in mature oilfields. *SPE Latin America and Caribbean Petroleum Engineering Conference*, pp. SPE-123072.



- She, H., Kong, D., Li, Y. L., Hu, Z., & Guo, H. (2019). Recent Advance of Microbial Enhanced Oil Recovery. *Geofluids*, 2019, 16. doi:<https://doi.org/10.1155/2019/1871392>
- Strappa, L. A., De Lucia, J. P., Maure, M. A., & Llopiz, a. M. (2004). A Novel and Successful MEOR Pilot Project in a Strong Water-Drive Reservoir Vizcacheras Field, Argentina. *SPE/DOE Symposium on Improved Oil Recovery*, (págs. SPE-89456). Tulsa, Oklahoma. doi:<https://doi.org/10.2118/89456-MS>
- Taber, J. J., Martin, F. D., & Seright, R. S. (1997). EOR screening criteria revisited—Part 1: Introduction to screening criteria and enhanced recovery field projects. *SPE reservoir engineering*, 12(03), 189-198.
- Town, K., Sheehy, A., & Govreau, B. (2009). MEOR Success in Southern Saskatchewan. *SPE Annual Technical Conference and Exhibition*, 13, págs. 773–781. New Orleans, Louisiana. doi:<https://doi.org/10.2118/124319-MS>
- Wang, W., He, Y., Wang, B., Dong, M., Zhang, H., & Shen, C. (2022). Experimental study on wax removal and viscosity reduction of waxy crude oil by *Ochrobactrum intermedium*. *Journal of Petroleum Science and Engineering*,, 213, 213.
- Wu, B., Xiu, J., Yu, L., Huang, L., Yi, L., & Ma, Y. (2022). Research advances of microbial enhanced oil recovery. *Heliyon*, Volume 8(11).
- Yasaman, C., Kord, S., & Mashayekhizadeh, V. (2023). A two-stage screening framework for enhanced oil recovery methods, using artificial neural networks. *Neural Computing and Applications*, 35, 17077-07094.
- Zahner, R. L., Tapper, S. J., Marcotte, B. W., & Govreau., B. R. (2011). What Has Been Learned From A Hundred MEOR Applications. *SPE Enhanced Oil Recovery Conference*. Kuala Lumpur, Malaysia. doi:<https://doi.org/10.2118/145054-MS>



Ziwei, B., Xiangchun, Z., Yiyang, W., Lusha, W., Yifei, W., & Hanning, W. (2021). Review on microbial enhanced oil recovery in China: mechanisms, potential disadvantages, and application of genetic engineering. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 1-16.