

Este artículo describe la tecnología y el proceso desde la adopción de los datos hasta el resultado del modelamiento, la selección del escenario óptimo y los resultados preliminares.

Aplicación de Data Physics, combinación de Física con Inteligencia Artificial (IA) en la optimización de los campos maduros

Por *Carlos Calad, Fernando Gutiérrez y Paola Pastor* (Tachyus)



por ejemplo, aumentar la producción y reducir los costos; aumentar reservas y reducir CAPEX; objetivos de largo plazo *versus* corto plazo.

- Existen numerosas restricciones operacionales (inyecciones máximas y mínimas en pozos o capas, capacidad de la planta de inyección, mantener inyección constante en el tiempo para pozos sumideros, etc.) que agregan un grado de dificultad mayor a la solución del problema.

Métodos tradicionales de solución

En la figura 1 se muestra el espectro de soluciones comúnmente utilizadas para resolver el problema de optimización que incluye soluciones numéricas (simuladores) y soluciones analíticas o basadas en datos.

Estos flujos tienen sus aplicaciones específicas; sin embargo, presentan falencias cuando son empleados para optimizar, como analizaremos a continuación.

Soluciones numéricas: los simuladores numéricos existen desde los años ochenta y son una de las herramientas más utilizadas en la industria. Las ecuaciones físicas que definen el movimiento de fluidos en un medio poroso son la herramienta que nos permite ver hacia adelante y predecir con un buen grado de confiabilidad el comportamiento futuro del campo. Ahora bien, la creación del modelo es un proceso secuencial complejo que normalmente toma desde meses hasta años en su ejecución; asimismo los simuladores numéricos demandan capacidad de cómputo significativa y cada corrida demora varias horas, días y en ocasiones semanas. En ese orden de ideas, es normal realizar un número limitado de corridas y elegir el escenario que presenta la mejor respuesta del campo, denominándolo normalmente como escenario “optimizado”. Pero, este escenario “mejorado” no necesariamente es un escenario óptimo y peor aún, la tecnología no permite estimar qué tan lejos estamos del escenario óptimo, para ello sería necesario correr cientos de miles de simulaciones, algo que no es factible debido a las necesidades computacionales y las restricciones de tiempo de esta tecnología. Estamos pues ante el dilema optimizar *versus* mejorar, como se muestra en la figura 2.

Soluciones analíticas: en el extremo opuesto del espectro de posibilidades están las soluciones analíticas, que normalmente proveen extrapolaciones válidas durante pe-

La optimización en la industria de E&P es uno de los problemas más complejos de resolver; sin embargo, su solución genera más valor en comparación a procesos alternos. A continuación, se listan algunas razones acerca de por qué es tan difícil encontrar soluciones óptimas para la producción de un campo:

- El alto número de posibles soluciones hace más difícil la búsqueda y el análisis exhaustivo de los posibles escenarios de optimización.
- La función objetivo es compleja lo que dificulta el planteamiento del problema desde el punto de vista matemático. Esta función objetivo es multimodal, presenta mínimos y máximos locales y globales y no es convexa, lo cual dificulta más aún el planteamiento y la solución matemática.
- Las soluciones existentes requieren alta capacidad de cómputo y, por lo general, las simulaciones numéricas requieren de horas, días y a veces hasta semanas para simular un único escenario predictivo.
- En general, se plantean múltiples objetivos de optimización que en ocasiones pueden parecer conflictivos;



Figura 1. Espectro de soluciones que se emplean en la industria.

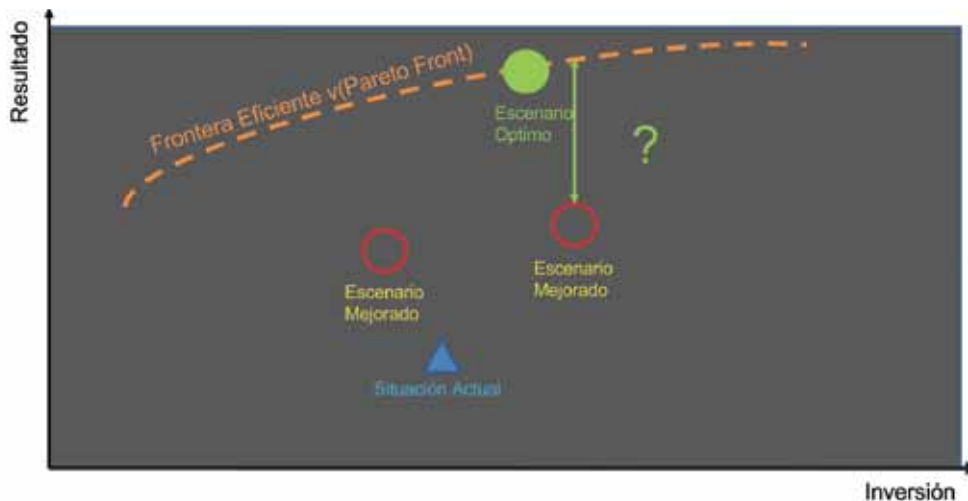


Figura 2. La diferencia entre optimizar y mejorar.

riodos relativamente cortos (meses) pues el hecho de no incorporar la física del reservorio limita la predictividad a largo plazo. Las soluciones analíticas tienen la gran ventaja de ser mucho más rápidas que las soluciones numéricas, pero son vulnerables a correlaciones de ruido (*spurious correlations*) y no son capaces de predecir situaciones que no se hayan presentado en los datos empleados para entrenar el algoritmo.

En pocas palabras, la solución ideal sería una que combine la capacidad predictiva de los modelos numéricos con la rapidez de modelado y la ejecución de las soluciones analíticas (Figura 3).

*Data Physics** la tecnología innovadora desarrollada por Tachyus es justamente esta solución, ya que combina la velocidad de métodos analíticos gracias a técnicas de inteligencia artificial y la capacidad de predecir a largo plazo dado que incorpora las leyes físicas de simulación de reservorios.

Aplicación de *Data Physics**

La aplicación de *Data Physics** para optimizar la producción de petróleo mediante la redistribución, disminu-



Figura 3. *Data Physics* llena el vacío y permite identificar soluciones óptimas.

ción o aumento de inyección de agua fue introducida en 2017 bajo el nombre de *Aqueon**, su objetivo es crear un modelo predictivo de alta velocidad para poder generar, con el empleo de técnicas de inteligencia artificial, cientos de miles de escenarios de manera que se identifica la frontera eficiente de operación del campo (*Pareto Front*). El flujo de trabajo de *Aqueon** se muestra en la figura 4 y se describe a continuación.

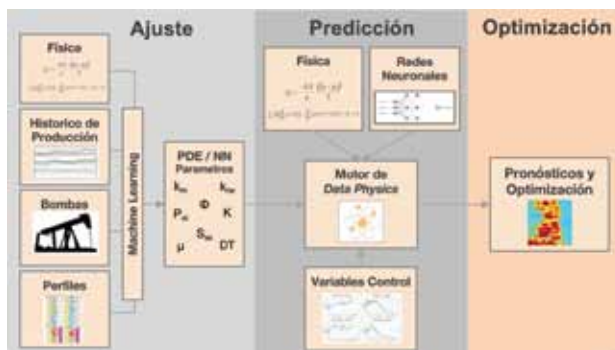


Figura 4. Flujo de trabajo de *Data Physics**.

Paso 1. Ajuste y creación del modelo

Durante este paso se entrena una red neuronal modificada que incluye la física del reservorio para encontrar los parámetros petrofísicos y geológicos que definen el campo, como permeabilidad, porosidad y viscosidad, entre otros. Para el entrenamiento se usa la técnica de Ensamble de Filtros Kalman (EnKF), se entrenan 96 modelos independientes y cada filtro (o modelo) es una descripción única del reservorio, se usan datos históricos de producción e inyección durante un período y luego se verifica la predictividad de los modelos “se ocultan” los valores de producción y se deja que el algoritmo prediga los valores, como se muestra en la figura 5. A este proceso se le denomina *Backtest*.

Cada punto rojo de la gráfica representa la producción acumulada calculada para cada modelo en un período



Figura 5. Entrenamiento del modelo o *Backtest*.

específico; los puntos negros representan la producción medida. En este ejemplo el entrenamiento se inicia el 01/01/2010 y finaliza el 31/12/2014. Terminado el período de entrenamiento, los 96 modelos (curvas azules) predicen la producción de cada pozo a partir de esa fecha, en este caso el inicio de la predicción es el 31/12/2014. Cada línea azul representa una predicción de producción total del campo durante un período; los puntos negros, como se mencionó anteriormente son la producción medida.

Para verificar la predictividad del modelo, se analiza la gráfica detalladamente con el fin de comprobar si las tendencias predichas por el modelo siguen el comportamiento histórico de la producción del campo y se utilizan coeficientes de correlación de Pearson y Spearman. Se entiende que un modelo es predictivo si los coeficientes de correlación son superiores a 0,6, por encima de 0,7 se asume que la correlación es muy buena y excelente cuando excede 0,8. Cabe recordar que los coeficientes de Pearson y Spearman reflejan la dispersión en la correlación de los datos.

En todos los casos aplicados en la Argentina se obtuvieron modelos predictivos que resultaron en coeficientes de correlación superiores a 0,6 y en algunos casos por encima de 0,8, como se muestra en la figura 6, donde se observa que los coeficientes logrados son Spearman 0,85 y Pearson 0,76.

Una vez que se obtiene un modelo con coeficientes de correlación satisfactorios se repite el proceso de aprendizaje, pero esta vez usando todo el período de la historia de

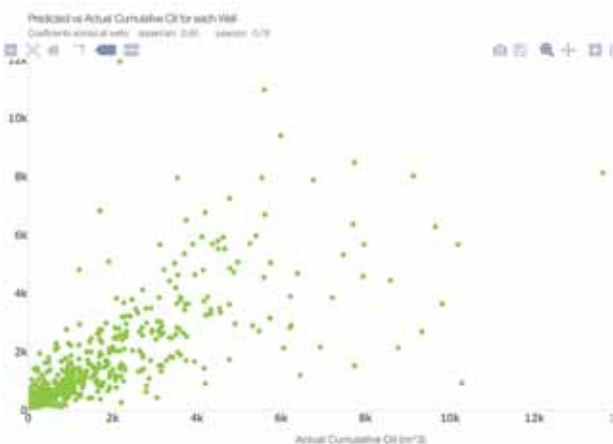


Figura 6. Producción real versus predicción.

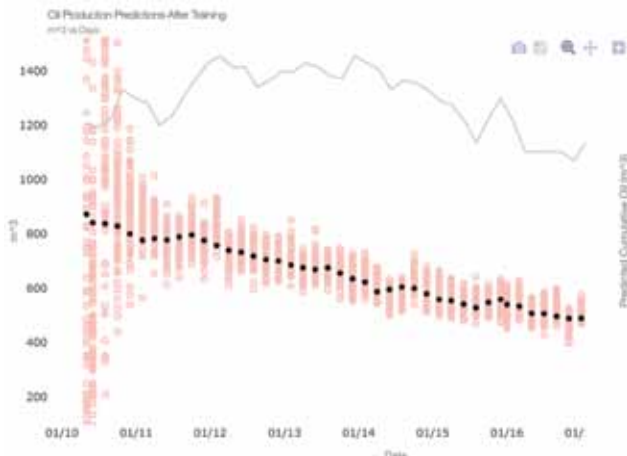


Figura 7. Entrenamiento durante todo el período *full fit*.

producción del campo, es decir, sin verificar predictividad con un período de la historia de producción, de manera que el modelo sea más robusto entrenándolo sobre situaciones que no fueron observadas durante este último período, como lo son los pozos in-fill durante ese período. Este proceso se denomina *full fit*, en este paso nuevamente se verifica la predictividad del modelo mediante coeficientes de correlación, como se muestra en las figuras 7 y 8.



Figura 8. Correlación de producción acumulada real versus predicción.

Paso 2. Predicciones

Una vez que se logra un modelo predictivo y se verifica su predictividad mediante los coeficientes de correlación, el motor de *Data Physics** puede generar cientos de miles de escenarios posibles y ordenarlos para encontrar la frontera eficiente; la manera eficiente de hacerlo es usar algoritmos genéticos generando sucesivos grupos de hijos hasta llegar al punto en que el modelo no encuentra soluciones mejores a las existentes, definido como la frontera eficiente o *pareto front*. En este paso también se alimenta el modelo económico con datos de entrada, como precios y costos que permitan a *Aqueon** ordenar los escenarios económicamente permitiendo análisis de ingresos, costos y VPN. Los escenarios de la frontera eficiente se presentan

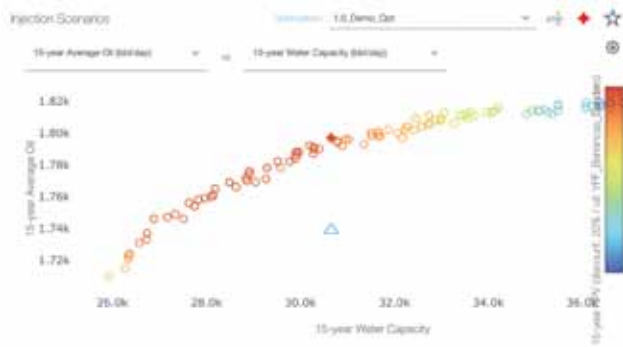


Figura 9. Frontera eficiente y escenario base.




Figura 10. Predicción de producción del escenario base.

gráficamente en la figura 9, para uno de los campos estudiados. El eje “X” muestra la inyección promedio diaria durante el período analizado y el eje “Y” (la producción acumulada durante ese período). El triángulo azul es el escenario “base” que representa la situación actual del campo, es decir, si se mantiene el plan actual de inyección en todos los pozos inyectoros. En este caso la producción acumulada durante los 15 años se calcula en 1.490.000 m³ de petróleo. Los puntos redondos coloreados representan los escenarios óptimos para cada valor de inyección y están ordenados según VPN.

También, la plataforma despliega otras curvas, como plan de inyección, *cash flow* asociado al escenario y predicción de producción (Figura 10).

A partir de la frontera eficiente, se pueden evaluar varios escenarios, por ejemplo, como se muestra en la figura 11, un escenario (rombo verde a la izquierda) que permite reducir significativamente la inyección de agua mante-



Figura 11. Selección de escenarios para evaluación y análisis.




Figura 12. Escenario de aumento de inyección.

niendo la producción; uno (rojo) que permite aumentar la producción mediante la redistribución de inyección; y uno (amarillo) que permite aumentar la producción con el exceso de agua disponible de otros campos cercanos.

La herramienta presenta cada uno de estos escenarios en una tabla “receta” del volumen que se debe inyectar en cada pozo inyector y su variación en el tiempo. También es posible visualizar el escenario como una gráfica mostrando el volumen de inyección de agua acumulado durante el período como se observa en la figura 12. Cada burbuja representa un pozo inyector, las burbujas rojas representan reducción de inyección y las verdes aumento (respecto del escenario base). Como se observa en la figura, la prescripción del escenario requiere reducir inyección en el sector norte-centro del campo e incrementar inyección en el sector sur y en algunos pozos del sector norte.

De la misma manera se pueden analizar todos los esce-

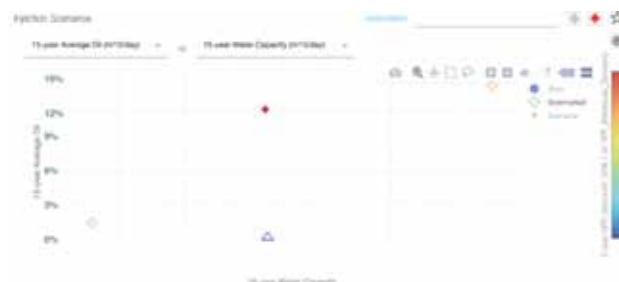


Figura 13. Escenario de redistribución de inyección.

narios integrando el conocimiento del campo y las restricciones operacionales y así decidir cuál es el escenario más apropiado para implementar.

Paso 3. Selección del escenario meta

En cada caso se selecciona un escenario objetivo que representa una meta de optimización específica de la operación del campo. Este artículo presenta un ejemplo de un escenario de redistribución de inyección (Figura 13), que no necesariamente corresponde a un escenario seleccionado por un cliente, y que después de su implementación, muestra un incremento de acumulación de producción de petróleo del 12,8% y del VPN 13% por encima del escenario base durante un período de 15 años.

Una vez seleccionado el escenario objetivo, se realizan modificaciones para adaptarlo a las condiciones operacionales del campo, que pueden incluir las siguientes:

- Limitar los caudales de inyección en algunos pozos, debido a restricciones operacionales (mandriles, líneas, etc.).
- Uso de caudales máximos, resultado de las pruebas de inyectividad realizadas en cada pozo.
- Reducir la frecuencia de intervenciones de pozos inyectoros (cada 6 meses en vez de mensualmente) con el objetivo de reducir costos y tener en cuenta la disponibilidad de la unidad de *slick line*.

En algunos casos se incluyeron restricciones a la producción mínima y máxima obedeciendo al diseño del sistema de bombeo instalado.

Resultados

En la primera implementación se comienzan a observar resultados positivos luego de 60 días de finalizar la redistribución de agua sugerida (Figura 14) presentando una reversión de la curva de declinación del campo y una generación de valor estimada hasta la fecha superior a USD 500.000 en los primeros noventa días.

Figura 14. Resultados iniciales de la implementación.

En los otros casos, los escenarios objetivo-finales, se están analizando y se está realizando el acondicionamiento en campo para iniciar su implementación. Se espera respuesta del campo entre 3-6 meses.

Conclusiones

La aplicación de la tecnología *Data Physics** ha demostrado varios beneficios para operadores de campos maduros en las tres principales cuencas argentinas:

- La posibilidad de crear modelos predictivos a partir de los datos históricos de una manera rápida (3-4 meses) reduciendo sustancialmente el tiempo de estudio comparando con métodos de simulación tradicionales.
- La generación de la frontera eficiente de operación del campo y la posibilidad de analizar los distintos escenarios que la componen facilita la identificación y cuantificación de la oportunidad de optimización, un

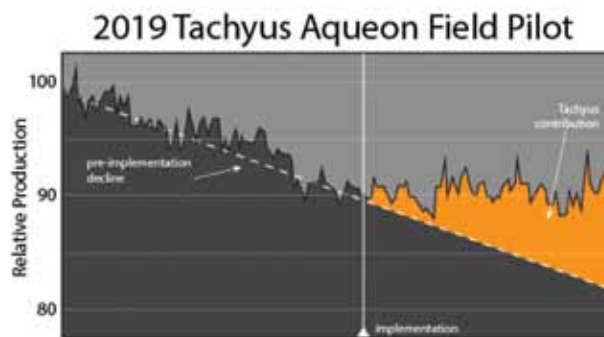


Figura 14. Resultados iniciales de la implementación.

flujo de trabajo que no es posible realizar con otros métodos.

- La rapidez de respuesta del modelo, que permite correr escenarios modificados en minutos y facilita varios tipos de análisis, incluso análisis de conectividad entre pozos inyectoros y productores, que de otra manera se tardaría varios meses en realizar.
- La herramienta cuantifica el beneficio de implementar cada uno de los escenarios seleccionados y provee una prescripción (receta) de los volúmenes a inyectar en cada uno de los inyectoros en tiempo, algo no disponible en otras aplicaciones comerciales.
- Los modelos creados se usan para otras aplicaciones, como la generación de las localizaciones óptimas de perforación de pozos *in-fill*.
- Una vez implementados los escenarios óptimos se han observado respuestas de algunos campos en 60 días aproximadamente, reflejando en una creación de valor significativa.
- Además de permitir optimización mediante redistribución de agua, la tecnología se ha usado para optimizar la reactivación de pozos inyectoros y para encontrar las locaciones óptimas de pozos *in-fill*, generando valor substancial en estos casos.
- El modelo de contrato SaaS (*Software as a Service*) y la utilización de la nube para el almacenamiento y el procesamiento implica que se puede usar la plataforma sin necesidad de contratar licencias individuales; no es necesario tener estaciones de trabajo especializadas, los ingenieros trabajan en las mismas computadoras de uso diario traduciéndose en un ahorro de infraestructura de TI. ■

Referencias

- Sarma, P, Kyriacou, S., Henning, M., Orland, P., Thakur, G., Sloss, D. 2017. *Redistribution of Steam Injection in Heavy Oil Reservoir Management to Improve EOR Economics, Powered by a Unique Integration of Reservoir Physics and Machine Learning*. Paper SPE 185507-MS presented at the SPE Latin America and Caribbean Petroleum Engineering Conference in Buenos Aires.
- Sarma, P, Kyriacou, S, Sack, D, Zhao Y, Lawrence, K. *Implementation and Assessment of Production Optimization in a Steamflood Using Machine-Learning Assisted Modeling*. SPE-193680 -MS. Presented at the SPE International Heavy Oil Conference and Exhibition 2017.