



Modelado y Simulación de reservorios: la búsqueda continúa

Puesto que esta edición de *Petrotecnia* tiene como protagonista el Modelado y Simulación de Reservorios, en este artículo se intentan repasar los puntos salientes, el status actual y una visión de hacia dónde creemos que va esta variada, importante y compleja disciplina con algunas reflexiones y comentarios generales.

Por **Ing. Fernando Tuero**, Presidente de la Comisión de Producción del IAPG

Dime qué preguntas y te diré quién eres

“La calidad de nuestro pensamiento está en la calidad de nuestras preguntas”, reza un enorme epígrafe al comienzo del libro *Critical Thinking*¹.

De hecho, nos cuesta imaginar a alguien que pensando bien, haga preguntas pobres. Por un lado, nuestras preguntas definen las tareas, expresan problemas y delimitan asuntos. Son nuestras preguntas las que impulsan el pensar hacia adelante. Por otro lado, están las respuestas que, de alguna manera, representan un pequeño descanso, una mera pausa hacia la próxima pregunta. Cuando una contestación genera otras preguntas, el pensamiento continúa la indagación y avanza en brindar futuras y mejores respuestas.

No hacer preguntas equivale a no comprender, mientras que realizar preguntas superficiales equivale a tener una comprensión superficial; e inquirir preguntas poco claras equivale a una comprensión poco clara.

El Modelado y Simulación Numérica de acumulaciones de hidrocarburos busca respuestas a una pregunta fundamental, la cual podría expresarse como: ¿cuál es la distribución temporo-espacial de saturaciones y presiones de una porción determinada de la tierra, y cuál será su interacción con los pozos (fuente o sumidero) y su entorno? Esas respuestas no serán totales ni satisfactorias, debido a la incertidumbre asociada a la información disponible y a los procesos reales que ocurren en los reservorios reales.

En este punto radica la importancia de hacer las preguntas correctas para obtener respuestas parciales que representen información fundamental para guiar la toma de decisiones, dado el estado de suficiencia y calidad de la información obtenida hasta ese momento.

Como conclusión, podríamos decir, que un buen Modelo de Simulación debería comenzar con una buena pregunta concreta y que mejore la capacidad de tomar una decisión; por ejemplo, ¿hasta cuánto puedo invertir en tal o cual información para que me agregue valor?, ¿hasta dónde me conviene expandir el desarrollo por inyección de agua?, ¿cuál sería el rango de distanciamientos que optimizan el valor del proyecto de una campaña de perforación *infill*?, ¿cómo optimizar el tratamiento hidráulico de un pozo horizontal multietapas?

El mejor ajuste ¿es aquel que no se logra?

En otros artículos hemos hablado sobre el “Efecto IKEA”² (efecto por el cual el esfuerzo invertido en un proceso o producto genera una identificación o agrado directamente proporcional a dicho esfuerzo) y hemos destacado la importancia que tiene comprender las hipótesis y las limitaciones que manejan nuestros modelos para lograr una mejor comprensión de la realidad o, al menos, de la “parte” de la realidad que más impactará en la decisión que debemos tomar.

En ese sentido, el proceso de ajuste histórico es una excelente oportunidad para “escuchar” al reservorio y, precisamente, aprender de los desajustes. Supongamos por un instante que, luego de varios meses de una ardua y detallada preparación de toda la información y modelo geológico, nuestro modelo dinámico corre y *voilà*, se ajusta de manera casi perfecta. Lo primero que vendrá a la mente de los geo-

cientistas involucrados será la irresistible idea de que dicho ajuste no es otra cosa que el fruto de ese enorme esfuerzo inicial y gran habilidad y experiencia para caracterizar debidamente el reservorio y sus condiciones de contorno.

Además de tener posibilidades infinitamente bajas de que eso ocurra (¡simuladores, a no esperanzarse demasiado!) no es más que una entre varias combinaciones posibles.

¿Por qué no puedo tener un número?

Atendiendo a la cualidad de “problemática inversa”³ del Modelado y Simulación, vemos que el valor que proporciona una solución no radica esencialmente en sí misma, sino en (ver Referencia 1) la información que logramos obtener en el camino para llegar a ella, como se mencionó anteriormente durante el ajuste histórico (ver Referencia 2) y en la capacidad para delimitar rangos de parámetros de salida (aquellos que más impactan nuestra decisión) en función de la variabilidad de los parámetros de entrada. Es decir, acotar las incertidumbres tratando de comprender como interactúan *inputs* y *outputs* en el modelo y sus implicancias en la toma de decisión.

Lo anterior implica poder manejar múltiples escenarios en uno o varios “pasos” en toda la cadena de Modelado y Simulación. Más aún, esto da por sentado que podremos comunicar esta multiplicidad de resultados e hipótesis a los destinatarios de nuestro modelado, los tomadores de decisión, y que ellos comprenderán este lenguaje.

En su libro *Why can't you just give me the number*, Patrick Leach⁴ explica en un lenguaje accesible esta odisea y cómo muchas veces los resultados de complejas simulaciones son presentados a ejecutivos que tienen que tomar importantes decisiones y comprender los impactos de estas incertidumbres para el beneficio de sus organizaciones. En la mayoría de los casos en los que esta comunicación no es la mejor, la responsabilidad, en general, es mutua. Por un lado, la falta de capacidad del tomador de decisión de comprender las limitaciones y los resultados que se obtienen de un proceso de simulación, pero por otro, la incapacidad del geocientista de poder transmitir sin abrumar con tecnicismos y presentando de manera correcta las preguntas adecuadas y las respuestas obtenidas⁵.

Algo similar ocurre en la interacción entre geocientistas en las distintas etapas del Modelado y Simulación (Estático, dinámico, escalamiento, ajuste, etcétera) en donde la clave es la integración.

Integración: buenos conflictos

Este tema es quizá uno de los más importantes en materia de Modelado y Simulación y debe ser entendido como un proceso, no como una colorida diapositiva con un *feedback-loop* que obligatoriamente debo incluir en mi presentación de PowerPoint. El reconocido neurólogo Ian McGilchrist⁶ lo resume de manera excelente en su último libro, *The Master and His Emissary*, en el que expresa: “[...] es en la confrontación de métodos y resultados contradictorios donde se crea conocimiento”.

No es casualidad que use las palabras “confrontación” y “contradicción”, ya que este es el momento en que de-

bemos parar y buscar en los datos y los resultados para encontrar sentido, esa es la pausa productiva en la Simulación, donde se avanza realmente en la comprensión de lo que puede estar ocurriendo en el reservorio, modelo, campo, sistema de flujo en cañerías, etcétera.

En este sentido es importante que todos los actores de la "Fabrica digital"⁷ se tomen el tiempo, que utilicen e integren toda la información que puedan conseguir (y la que no puedan conseguir también) y que interactúen continuamente con sus pares en las disciplinas que producen estas piezas de información, para lograr que esas contradicciones se transformen en respuestas consensuadas. Esto no implica que debemos tener modelos muy complejos ni que tengamos que simular o modelar de la manera más perfecta absolutamente todos los procesos hasta las últimas consecuencias, sino que construyamos el mejor modelo para responder a las preguntas que impacten en la decisión de desarrollo. A veces, menos es más.

¿Menos es más, más es más o más es menos?

Si bien Martin Crick⁸ comenta en 2013 que observa en los últimos tres años una tendencia en algunos sectores a utilizar modelos cada vez más simplificados, también observamos que las ofertas de herramientas de modelado vienen con más y más opciones ofreciendo nuevas herra-

mientas para "resolver" problemas con los que hemos luchado por años (por ejemplo, los sistemas multifásicos y multicomponente, la incorporación de la geomecánica y/o intercambio de calor, el transporte de masa por difusión, desorción, etcétera). Esta multiplicidad de opciones y herramientas nos da la sensación de que deberíamos usarlas todas al mismo tiempo o necesariamente nuestro modelo carecerá de "representatividad".

Ningún modelo composicional logrará representar la variedad de moléculas que coexisten en un reservorio real. El más sofisticado programa de flujo en cañerías no escapa de ser una aproximación de la complejidad enorme de los fenómenos interactuantes. El más avanzado simulador de geomecánica sigue teniendo una escala bastante gruesa del modelo de esfuerzos y una aproximación bastante cruda de sus condiciones de contorno.

Intentar construir un modelo "exacto" del reservorio y sus interacciones con el fluido es como intentar llegar al final del arcoíris. Nos hará perder mucho tiempo y esfuerzo en complejidades que no necesariamente serán críticas para ayudar a tomar mejores decisiones.

Y un día, llegaron los "no convencionales"

En la medida que el desarrollo de los no convencionales tomó importancia, primero en los Estados Unidos y luego en el mundo, un set de preguntas casi incómo-

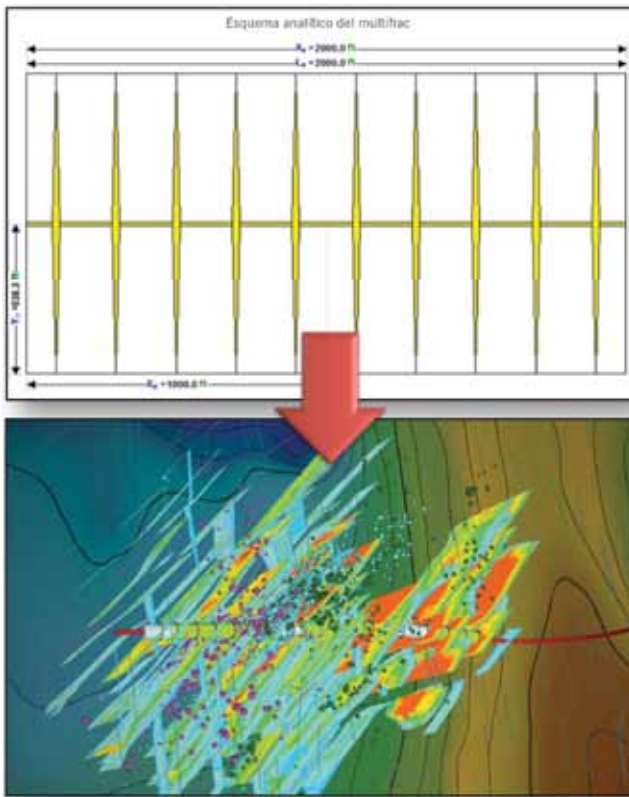


Figura 1. Evolución de los modelos simples analíticos representando el SRV (arriba) hacia numéricos que incorporan la complejidad inherente a los procesos de fracturamiento hidráulico en no convencionales (abajo).

das comenzaron a sonar como campanas en la comunidad de las geociencias: ¿las herramientas actuales son capaces de modelar los procesos fundamentales en los sistemas no convencionales?, ¿podrán explicar y aún más, podrán pronosticar el comportamiento de la producción en estos escenarios tan heterogéneos y variables?

En última instancia, la pregunta no es si lo lograrán, sino si sus resultados serán suficientemente confiables para mejorar la toma de decisiones de inversión (que para colmo de males, en estos casos, son muy intensas en la primera parte del proyecto, donde hay menor conocimiento).

En el momento en que irrumpieron en escena los no convencionales, el arsenal existente de herramientas de simulación y modelado estaba bastante probado, o al menos aceptado, para los reservorios convencionales.

Imaginemos por un momento la incómoda situación de estar en una escalera con un destornillador en una mano con la necesidad de clavar el clavo que tenemos en la otra mano. Es natural y hasta eficiente, probar si el mango del destornillador tiene al menos alguna posibilidad de lograrlo antes de bajar a buscar el martillo. Al segundo doloroso golpe en el dedo, confirmaremos que, efectivamente, será mejor bajar y buscar el martillo.

Análogamente, el primer paso fue intentar adaptar lo existente y evaluar su aptitud para lograr el objetivo.

Ante los primeros “golpes” o dudas de si sería posible esta tarea, inicialmente tomaron fuerza los tradicionales análisis empíricos como las Curvas Declinatorias (DCA) o técnicas analíticas de Análisis de Transientes de Caudales (RTA, por sus siglas en inglés) heredado del Análisis de Transientes de Presión (PTA, por sus siglas en inglés) y se acuñaron térmi-

nos como el SRV (*Stimulated Reservoir Volume*) y DFN (*Discrete Fracture Network*) en un intento de explicar las posibles contribuciones de la matriz y la red de fracturas y de optimizar la estrategia de desarrollo (espaciamiento, longitudes de rama lateral, etapas de fractura, etcétera).

Dichas aproximaciones fueron útiles durante un tiempo, pero no respondían preguntas de relevancia sobre cómo optimizar los tratamientos, cuántos punzados y a qué distancia hacerlos, interferencia de unas fracturas con otras.

Con una capacidad de respuesta excepcional, la industria y la comunidad geocientista logró gradualmente agregar herramientas y modelos más completos (Figura 1) que incluían desde la geomecánica y la descripción explícita de la red de fracturas inducidas y su interacción con las naturales, hasta la inclusión de procesos de transporte de masa adecuados, múltiples dominios de porosidades y permeabilidades, fuerzas capilares, etcétera, como necesidades para explicar las observaciones de campo⁹, que no cerraban con la lógica convencional.

Este artículo aún se sigue escribiendo día tras día y resulta apasionante ver cómo ciertas líneas de trabajo crecen y se consolidan incluso contradiciendo a otras preexistentes.

El cuarto paradigma: *Big Data*

Jim Gray, un pionero de la tecnología de bases de datos y principal investigador del Microsoft Research Institute¹⁰, en su ensayo *The Fourth Paradigm* hace una interesante mención a los cuatro paradigmas de la ciencia (Figura 2).

Hace unos milenios, la ciencia era empirismo puro, en su intento por describir los fenómenos naturales mediante su observación. En los últimos cientos de años, nace la rama teórica de la ciencia que crea modelos de dichos fenómenos, busca generalización y categorización principalmente mediante técnicas analíticas, ecuaciones, etcétera.

En las últimas décadas, y con los avances de la tecnología y la colaboración cruzada de disciplinas, la comunidad científica de alguna manera “acepta” que los fenómenos por describir son demasiado complejos y difíciles para resolver analíticamente y busca una aproximación numérica mediante el uso de simuladores.

Paradigmas de la ciencia

1. Miles de años atrás, la ciencia era empírica y describía fenómenos naturales.
2. Hace unos pocos cientos de años hubo una proliferación de teorías usando modelos o generalizaciones.
3. En unas pocas décadas se produjo un gran avance en la simulación.
4. Actualmente, la información exploratoria (o *Science*) unificó teorías, experiencias y simulación.
 - La información es recogida por instrumentos o generada mediante un simulador.
 - Existe un software para procesar dicha información.
 - La información y el consiguiente conocimiento se almacenan en computadoras.
 - Los científicos analizan las bases de datos y los archivos procesando los datos y con estadística.




Figura 2. Los cuatro paradigmas de la ciencia (Jim Gray).

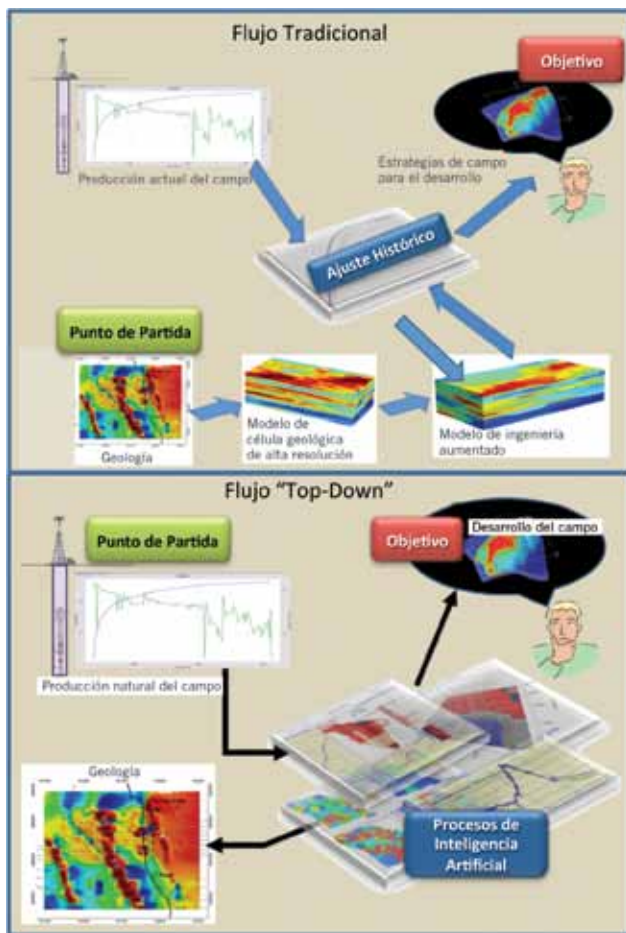


Figura 3. Diferencias fundamentales en el flujo de trabajo de los modelos guiados por datos (ejemplo, *Top-Down Reservoir Model*) versus flujos tradicionales.

Actualmente, existe una masiva generación de datos que hace que sea virtualmente imposible sacarle provecho a todo ese valioso cúmulo de información. Los expertos en el tema avalan cifras que van de un 10% a un 20% cuando se trata del uso de la información estructurada¹¹. Es decir, solo del 10% al 20% de toda la información que se genera logra estructurarse y, por ende, será más fácilmente aprovechable por métodos computacionales tradicionales. Como consecuencia, el desafío será cómo usar el otro 80-90% de la información generada.

Esta pregunta nos acerca al futuro y nos zambulle en el mundo de los datos, la nube, los métodos holísticos y la inteligencia artificial, rompiendo el tercer paradigma de la ciencia y dejándonos en la puerta del cuarto. El tiempo dirá si este es el camino o volveremos al ábaco.

Toda la información es valiosa y toda la información correctamente almacenada podría eventualmente utilizarse. El desafío es poder utilizar tanta cantidad, de manera eficiente, rápida y consistente para lograr “desentrañar” del seno de la información, mensajes o conclusiones útiles para la toma de decisiones.

Los procesos “Guiados por Datos” (*Data Driven*), o la “Minería de Datos” (*Data Mining*) como normalmente se los conoce, si bien no son una novedad, han tomado un ímpetu muy importante en la última década en su aplicación a procesos de perforación de pozos, optimización de la producción, manejo de reservorios, Simulación y Modelado.

¿Qué es un Proceso Guiado por Datos? Es la capacidad que tiene un proceso (generalmente computacional) de extraer sentido o significado de un conjunto de datos¹². Si bien la definición pareciera ociosa y simple, hoy en día, la avalancha de datos que se generan en toda la cadena de exploración y producción hace que los modelos guiados por datos hayan pasado de ser una “curiosidad científica” a una realidad y una necesidad.

¿De qué tipo de datos estamos hablando? En general estos procesos, se aprovechan para analizar sets de datos no estructurados, voluminosos, complejos, heterogéneos y recabados a muy altas frecuencias y a diferentes escalas. El término típicamente utilizado para describir estos sets de “Datos grandes” es *Big Data*. Para el caso del petróleo y del gas pueden ser desde datos económicos de fluctuaciones de demanda, pasando por grillas de simulación, mapas, propiedades petrofísicas hasta partes de operaciones, perforación, mediciones de sensores de presiones, temperaturas, profundidades, vibraciones, etcétera.

Recientemente, desde 2013 se llevan a cabo en los Estados Unidos regularmente conferencias¹³ dedicadas exclusivamente a este tipo de problemáticas. En ellas confluyen la industria informática (IT, por sus siglas en inglés) y la petrolera, para explorar soluciones inteligentes a la problemática del uso de técnicas *Data Driven* y de inteligencia artificial para procesar *Big Data* como soporte en la toma de decisiones.

Hay casos muy interesantes en donde por ejemplo, la aparición de una palabra, de manera cada vez más frecuente en los partes de operaciones, estaba positivamente correlacionada con incidentes de roturas en bombas. Esto permitió la detección temprana y la prevención de roturas ahorrando enormes costos y tiempos para el operador.

¿Qué tan artificial es la inteligencia artificial?

Entendemos la inteligencia artificial como la capacidad de incorporar a las computadoras, procedimientos que emulen la inteligencia humana. En este plano, algoritmos de cálculo como las redes neuronales, la lógica difusa, la computación evolutiva o los algoritmos genéticos están dentro de las herramientas más utilizadas en la industria¹⁴. Estas herramientas son utilizadas en conjunto con los datos generados en el campo (por ejemplo, producción, presión, mediciones de perfiles, etcétera) para construir modelos que interpretan las relaciones subyacentes entre esos datos y sus resultados de una manera “inteligente” y construyen reglas que luego se aplicaran a nuevos datos permitiendo la predicción de nuevos resultados.

Estos modelos “sustitutos”, o *Surrogate Models*, son algunos de los ejemplos más resonantes de este tipo de aplicación, así como también los modelos denominados “de arriba a abajo” (*Top-Down Reservoir Models*).

En ambos casos, se modifica el tradicional flujo de trabajo de modelado estático y simulación (Figura 3) para dejar que los datos “hablen por sí mismos” y nos permitan interpretar lo que está ocurriendo ahí abajo, para extraer conclusiones útiles a la hora de planificar o ampliar un desarrollo.

El principal beneficio de este tipo de acercamiento es el tiempo computacional requerido, en general, muy bajo

respecto de los de una simulación numérica tradicional, mientras que la principal limitación es que están “entrenados” para un tipo de problemática en particular (*Problem Oriented*) y en la medida que esos procesos fundamentales cambien, la representatividad del mismo puede verse gravemente comprometida; por ejemplo, un modelo ajustado y entrenado, con historia de producción generada por explotación primaria, podría presentar graves dificultades al intentar reproducir los procesos de barrido en una implementación de un proyecto de inyección de agua.

Conclusiones

La búsqueda continúa y el universo de herramientas crece acompasado con el uso intensivo de las mismas en la industria, así como también de la integración de múltiples disciplinas tecnológicas y científicas que confluyen en la disciplina del Modelado y Simulación. A continuación se agregan algunas reflexiones para ayudar a que la búsqueda sea más efectiva:

- Todo debería comenzar con una buena pregunta, un objetivo, una dirección clara y concisa que permita dirigir constantemente el esfuerzo e impida que se pierda el foco en el enredo de opciones que se presentarán a lo largo de un análisis de este tipo.
- Cualquiera sea el proceso de ajuste seleccionado, el mismo deberá ayudar a comprender los principales procesos físicos que impactarán en las respuestas que tendremos que proporcionar de la manera más efectiva posible y sin perder la oportunidad de aprender de las contradicciones y los desajustes.
- La integración de las disciplinas es fundamental para enriquecer los modelos y el análisis de simulación, aprovechando las herramientas actuales con flujos de trabajo cruzados.
- Los resultados deberán ser pensados, obtenidos e informados de una manera que represente y comunique al tomador de decisión, la incertidumbre inherente a los datos y las limitaciones del proceso de simulación en sí mismo.
- La retroalimentación del modelado, mediante posteriores ajustes históricos que incorporen las diferencias observadas durante la operación y producción continuadas, es fundamental para guiar metodológicamente al proceso de adquisición de conocimiento, beneficiando las etapas posteriores de un proyecto de desarrollo o las de un proceso productivo.
- Pareciera que el futuro de esta disciplina continúa su proceso de crecimiento y avance en dos focos principales. Por un lado, tiende a simplificar las cosas para no perderse en el ruido, pero por otro incorpora constantemente nuevas herramientas complejas que buscan emular la inteligencia humana y sacar provecho a la creciente masa de datos generados.

La buena noticia es que, a pesar de sus limitaciones, el Modelado y Simulación sigue siendo una de las más completas herramientas con la que contamos para comprender mejor nuestros reservorios, planificar, desarrollar y tomar decisiones de inversión en la industria. ■

Referencias

1. *The Miniature Guide to Critical Thinking Concept & Tools*, Paul R., Foundation for Critical Thinking, 2014.
2. “Modelado y Simulación de Reservorios, ¿ciencia artesanal o artesanía científica? (Una visión no técnica)”, Tuero F. R., *Petrotecnia*, IAPG, abril 2012.
3. Un “problema inverso” es aquel que se soluciona partiendo de las conclusiones hasta llegar a las causas, conocemos los efectos pero no estamos seguros del origen. Es decir, tienen más de una solución posible lográble mediante diferentes combinaciones de las variables de entrada.
4. *Why Can't You Just Give Me The Number? An Executive's Guide to Using Probabilistic Thinking to Manage Risk and to Make Better Decisions*, Leach P., Probabilistic Publishing, septiembre 2006.
5. Estas situaciones se podrían minimizar ejecutando correctamente un proceso de gestión de proyectos. El desarrollo se construye por etapas y el ejecutivo solo decide por las opciones que le vienen adecuadamente presentadas y recomendadas.
6. *The Master and His Emissary, The divided Brain and The Making of The Western Society*, Mc Gilchrist I., Yale University Press, 2010.
7. Modelado y Simulación de Reservorios “Petróleo digital”: usos, abusos y algunas reflexiones, Tuero F. R., SPE Contacto, septiembre 2015.
8. *Journal of Petroleum Technology, Reservoir Simulation foreword*, SPE, July, 2013.
9. “Inyección de agua en reservorios shale oil - El impacto de los fenómenos capilares sobre la producción”, Crotti M., Labayén I., INLAB S.A., *Petrotecnia*, diciembre 2104.
10. Microsoft Research es una institución que nuclea a más de 1.000 científicos e ingenieros trabajan a través de múltiples áreas de investigación en distintos laboratorios de investigación en todo el mundo, haciendo contribuciones significativas en los productos y colaborando en proyectos externos que ayudan a resolver retos mundiales. <http://www.research.microsoft.com>
11. Si bien no hay una definición única, se denomina “estructurada” a la información que se almacena en el formato de bases de datos con un esquema de tipo campos y registros (lo más parecido a una planilla Excel con filas y columnas y contenidos en dichas celdas). Todo el resto será “no estructurada”. Ejemplo, una base de producción con pozo, fecha, caudal de petróleo es “estructurada” y de fácil acceso, análisis y carga en un simulador mientras que un PDF que contenga todos los reportes de terminación con las fotos de la fosa de quema, párrafos de texto, organigramas pegados como metarchivos, etcétera sería “no estructurada”.
12. *Harness Oil and Gas Big Data with Analytics*, Keith Holdaway, Wiley & Sons, 2014.
13. *Big Data Analytics for Oil and Gas*, 017-18 Oct-2013, Houston, Tx, USA, “Data Driven Production Optimization Conference”, 16-17 Jun-2013, Houston, Tx, USA, “Big Data Solutions & Analytics in Oil and Gas Industry”, SPE, 10 Feb-2015, Oslo, Noruega.
14. “Artificial Intelligence Come of Age in Oil and Gas, Gentry Braswell”, *Journal of Petroleum Technology*, January 2013.