



# Ajuste de historia y pronóstico con incertidumbre, una aplicación real

Primera parte

Por **Ing. Gustavo Gabriel Becerra**, Petrobras Argentina S.A.



**Las incertidumbres geológicas, de reservorio, económicas y tecnológicas; la imprecisión y la falta de datos confiables afectan las decisiones de gerenciamiento de reservas y de los planes de desarrollo e incrementan el riesgo de la predicción de producción, por esta razón es indispensable una calibración del modelo dinámico con los datos de producción del campo. Este trabajo busca la integración del ajuste de historia con el análisis probabilístico de los escenarios representativos, a fin de estimar un rango representativo de las reservas que se desarrollarán. Basado en un caso real de un reservorio de la Cuenca de Campos, Brasil, el objetivo no busca conseguir el mejor ajuste determinístico, sino mostrar cómo el proceso de ajuste probabilístico del período histórico permite mitigar las incertidumbres identificadas.**

**E**n el período histórico es importante conocer el grado de precisión de las mediciones, con el objetivo de conseguir un comportamiento dinámico confiable. Las mediciones pueden tener diferentes tipos de errores que influirán en el resultado. Un ajuste de historia es considerado un problema inverso, lo que implica la existencia de varias respuestas posibles que pueden ser filtradas por medio de la aceptación de una banda alrededor de las mediciones históricas. Incluso con largos períodos no hay ninguna garantía de que el pronóstico se limite a esta banda, y puede existir una dispersión importante en el comportamiento de las curvas de producción. Una pregunta que deberíamos hacernos es ¿cómo podemos representar el futuro a partir de este conjunto?, destacando que aun contando con un extenso registro histórico de datos de producción, no siempre tendremos la garantía de que el pronóstico se restrinja a esta banda.

Podemos definir a la incertidumbre como el grado de conocimiento asociado con los atributos o parámetros que configuran un modelo. Es una magnitud asociada con la falta de información geológica, tecnológica o económica. Existe una cuarta categoría que engloba a las tres anteriores denominada sistemática y que representa los errores o “ruidos” propios de las observaciones de cualquier magnitud.

Un modelo es una representación numérica del sistema real (en este caso un reservorio de hidrocarburo) a través de parámetros o atributos descriptivos de propiedades físicas que lo caracterizan. Llamaremos “variables bajo análisis” a las respuestas calculadas con la simulación mediante una configuración específica del modelo funcional y representativo (por ejemplo,  $N_p$ ,  $Q_o$ ,  $Q_w$ , VAN).

La función objetivo (FO) cuantifica la diferencia entre los valores de los datos observados y los simulados durante un determinado período, depende del problema de estudio y del método utilizado. También puede referirse a una magnitud absoluta de una respuesta en análisis.

Para el alcance de este trabajo se define riesgo como el grado de variación de las FOs analizadas con los escenarios posibles. Representa un valor asociado con el grado de impacto técnico-económico que tiene una decisión en función de la incertidumbre presente. Representa a la evaluación de las consecuencias (positivas o negativas) de una elección e incorpora las incertidumbres críticas del problema bajo análisis.

El campo utilizado para este trabajo se encuentra en la cuenca de Campos en Brasil, a unos 80 km de la costa. El yacimiento es conformado por depósitos turbidíticos siliciclásticos bajo una lámina de agua entre 300 y 800 m. Estas areniscas son predominantemente masivas, con características acanaladas y gran distribución horizontal.

El depósito de arena principal tiene buenas características petrofísicas (más o menos del 27% de porosidad y 3000 mD de permeabilidad) y también un petróleo de buena calidad (29° API y 2.1 cp viscosidad).

El campo tiene una alta relación arena/arcilla y varias fallas normales, lo que resulta en bloques que pueden tener ciertas restricciones de comunicación hidráulica. El bloque principal se divide en tres zonas estratigráficas, separados por discordancias, pero conectados hidráulicamente. En la figura 1 se muestra la división del bloque de producción.

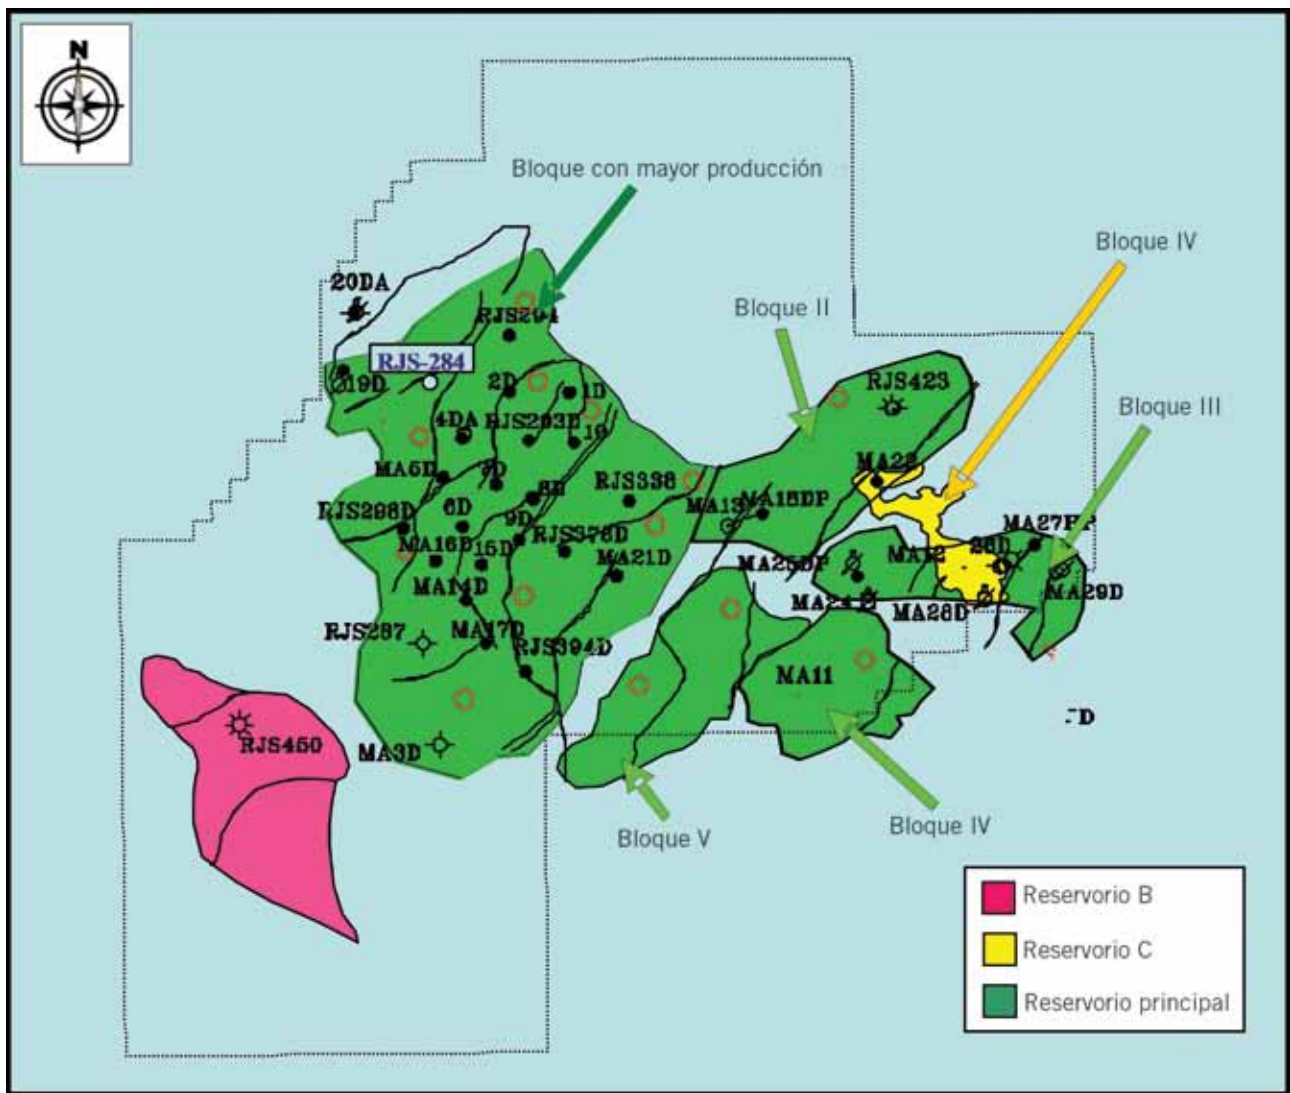


Figura 1. Reservorio principal y ubicación de los bloques de producción del campo.

Los primeros catorce años de producción se centraron en la región norte del campo y causaron una depleción significativa debido a la falta de inyección de agua. La producción de agua en este período se debe al efecto del acuífero. Posteriormente, se inició la inyección de agua y se expandió la producción en la región sur. En este período fue necesario re-completar varios pozos para evitar la producción excesiva de agua, siguiendo la estrategia definida para el campo, que consistió en el taponamiento de los intervalos más bajos ya barridos por los frentes de desplazamiento del agua y el punzado de los intervalos superiores.

Para este estudio fueron considerados solo los primeros catorce años de producción como datos observados. La producción de los años siguientes fue tratada como desconocida, y se predijo directamente con el modelo de simulación.

No forma parte del alcance de este trabajo la validación exhaustiva del rango de los posibles pronósticos obtenidos a través de toda la historia de producción registrada. Solo se considera una parte de los datos históricos reales con el objetivo de aplicar la metodología presentada en este modelo.

## Objetivo

El objetivo de este trabajo es presentar un ejemplo práctico de un análisis de incerteza en el nivel global en un campo con historia de producción.

Se propone una metodología para identificación de modelos representativos ajustados dentro de un rango de aceptación definido, normalmente limitado por una tolerancia determinada, en lugar de obtener el mejor modelo ajustado posible. El propósito no pretende obtener el mejor ajuste determinístico, sino mostrar cómo el proceso de ajuste histórico probabilístico posibilita una mitigación de las incertidumbres identificadas (Becerra, 2007). Se busca obtener una forma más robusta de identificación de los atributos críticos que configuran los modelos con ajustes representativos y la variabilidad de sus respuestas. Un propósito secundario del trabajo es la identificación de las limitaciones, las ventajas y las desventajas de los programas utilizados ante la disponibilidad de opciones y procedimientos semejantes.

Para desarrollar este análisis se estableció una metodología y se recurrió al uso en forma paralela de dos herra-



mientas comerciales (se usaron las versiones 2013 de los softwares, algunas mejoras técnicas ya han sido implementadas desde entonces). La herramienta A fue desarrollada por un proyecto industrial conjunto (*Joint Industrial Project*) dirigido por el IFPEN/Beicip-Franlab, con la participación de Petrobras y otras empresas como patrocinadores. La herramienta B está disponible en el conjunto de programas de CMG.

## Antecedentes

El enfoque multidisciplinario para un ajuste de historia combinado con un análisis de incertidumbre es bastante reciente (aproximadamente diez años) y se puede encontrar en la literatura técnica una variedad de procedimientos. Roggero (1997), Christie *et al.* (2002) y Kashib y Srinivasan (2006) proponen métodos basados en probabilidades condicionales que siguen el formalismo bayesiano, para actualizar la distribución de atributos geológicos, considerando la información incluida en las respuestas dinámicas de las variables observadas.

El uso de métodos estadísticos es otra línea de análisis. En este sentido, Gu y Oliver (2004) aplicaron el método de filtro de Kalman para obtener automáticamente múltiples modelos ajustados para la estimación posterior de la incertidumbre en las predicciones. Alvarado *et al.* (2005) señalaron la importancia de la cuantificación de la incer-

tidumbre en las predicciones de producción. Propusieron una metodología que considera la distribución de probabilidad del período de predicción, que se basa en la calidad y el peso atribuido al ajuste de una función objetivo definido para el período histórico.

Enfoques similares en este tema de investigación son presentados por Williams *et al.* (2004) y Ma *et al.* (2006). Queipo *et al.* (2002) presentan una metodología basada en el uso de redes neuronales artificiales y la optimización global eficiente para el cálculo de la distribución espacial de la permeabilidad y la porosidad en reservorios heterogéneos con múltiples fluidos, a través de la calibración de los datos estáticos y dinámicos disponibles.

Basados en el uso de algoritmos de optimización, Nicotra *et al.* (2005) y Rotondi *et al.* (2006) desarrollaron métodos de predicción de la producción y cuantificación de la incertidumbre utilizando algoritmos de vecindad más próxima (*k-nearest neighborhood algorithm*), que consisten en el uso de un muestreo estocástico para buscar una coincidencia aceptable de los datos observados. Suzuki y Caers (2006) también sugirieron este tipo de algoritmos en conjunto con un proceso geoestadístico de múltiples puntos. En su trabajo, cada escenario se describe cuantitativamente como una imagen de entrenamiento y una realización de un modelo geológico, ambas estocásticamente generadas.

En Petrobras existe una creciente necesidad de metodologías que permitan evaluar las incertidumbres y mitigarlas usando los datos históricos. Estudios recientes tratan de lo-

gar este objetivo, pero aún no hay una directriz consolidada. Reis (2006) propone un enfoque de uso de la relación diseño de experimento/Superficie de Respuesta, con un filtro vinculado a descartar simulaciones de Monte Carlo que no reproduzcan los datos observados y también hace uso de la técnica de redes neuronales artificiales para combinar el análisis de riesgo con el ajuste de historia. Esta metodología fue aplicada a otro campo brasileño *off-shore* por Lisboa y Duarte (2010), con el objetivo de ubicar dos nuevas locaciones. El uso de modelos representativos a fin de cuantificar las incertidumbres de un campo con producción fue abordado por Costa (2009). Otros trabajos han sido presentados internamente, pero no resultaron en artículos escritos.

A partir de la revisión bibliográfica, se puede deducir que el análisis combinado de incertidumbre y riesgo con la historia es un tema que acepta diferentes enfoques. Este estudio utiliza datos históricos para reducir el rango de incertidumbre en los parámetros de entrada, lo que conduce a un conjunto de modelos representativos con mejores capacidades de predicción. El impacto de las nuevas distribuciones de los parámetros en las respuestas de los modelos se evalúa por medio de simulaciones de Monte Carlo en base a un modelo *proxy* para determinados tiempos (superficie de repuesta polinómica o derivada de interpolación *kriging*), construido a partir del diseño experimental.

Para evaluar la calidad del ajuste de un determinado modelo, es necesario poder cuantificarlo. En este trabajo, y en la mayoría de los aplicativos comerciales, se llama Función Objetivo (FO) a la distancia entre los datos observados y los simulados. Esta cuantificación es ligeramente diferente en cada una de las herramientas, los detalles se abordarán en otra sección.

En la herramienta A, fueron realizadas corridas de simulaciones de confirmación, de manera iterativa, lo que permitió validar las SR (Simulación representativa) alrededor de los mínimos de la FO, aumentando gradualmente su calidad en las zonas de menor valor de la función objetivo. Posteriormente, un filtro aplicado sobre las SRs mejoradas en la zona de los mínimos permitió la obtención de diferentes modelos representativos ajustados, que serán usados para evaluar el grado de dispersión de las respuestas en el período de pronóstico.

En la herramienta B, el filtro se aplica directamente a las tentativas de solución del algoritmo de optimización utilizado para el ajuste de historia. En esta alternativa, las simulaciones de flujo se utilizan directamente en lugar de los modelos *proxy*.

Finalmente, para obtener un análisis de incertidumbre completo para el período de previsión, parámetros que no tienen influencia en el período HM, pero que repercuten en el pronóstico, deben ser identificados e incluidos en el análisis. La gama de nuevas curvas de producción de previsión (con dispersión reducida) se utilizará para evaluar la viabilidad del proyecto.

## Consideraciones sobre el ajuste de historia con incertidumbre

Tres características son fundamentales en la toma de decisión con incertidumbre en el desarrollo de un campo productor de hidrocarburos:

- En cada paso del modelado geofísico, geológico y de reservorios, la incertidumbre es propagada desde cada etapa y disciplina, y nuevas incertidumbres son integradas en la medida que son identificadas.
- En las simulaciones de los modelos dinámicos, el hecho de realizar el ajuste de historia conduce a una reducción de la distribución de la incertidumbre a priori (grado de conocimiento inicial).
- La incertidumbre remanente (resultante de las distribuciones *a posteriori* y de la inclusión de nuevos parámetros controlables a optimizar) impacta sobre la toma de decisión de los futuros desarrollos del proyecto y debe ser considerada en el análisis de riesgo de las inversiones.

Los principales pasos que se deben considerar en la etapa de modelado dinámica con incertidumbre son los siguientes:

- **Paso 1:** sensibilidad y análisis de incertidumbre inicial.

El propósito fundamental es identificar y caracterizar la incertidumbre asociada al problema (*bracketing the history*). Además, se busca definir los criterios para evaluar y medir el grado de ajuste de los datos observados (tipo y formulación de las funciones objetivo) y seleccionar aquellos atributos inciertos con mayor influencia en el ajuste asistido para la posterior propagación de la incertidumbre en los pronósticos de producción.

- **Paso 2:** ajuste de historia asistido con reducción de la incertidumbre.

El objetivo principal es la caracterización de la incertidumbre remanente. Diversas herramientas comerciales, como *Enable*, *Mepo*, *CondorFlow*, *Nexus* pueden utilizarse en esta fase; además de *Cougar* y de *CMost* utilizadas en este trabajo.

- **Paso 3:** optimización del plano de desarrollo con incertidumbre remanente.

El objetivo es obtener la mejor estrategia sobre qué tipos y qué controles aplicar en los pozos.

### Paso 1. Sensibilidad y análisis de incertidumbre inicial

Algunas preguntas frecuentes en la fase inicial de esta etapa son ¿los modelos estáticos y dinámicos seleccionados son los correctos?, ¿es posible reproducir el comportamiento observado?, ¿conozco y estoy considerando realmente todos los parámetros inciertos del problema?, ¿los rangos de variación de los atributos son adecuados y representativos?

Una de las principales razones para realizar un análisis de sensibilidad es mejorar el conocimiento del fenómeno y su respuesta a los cambios en los parámetros que lo afecta y, a la vez, reconocer aquellos con mayor influencia. Además, este paso permite la cuantificación de la influencia primaria y de la interacción entre los parámetros que pueden afectar el ajuste.

Un análisis de sensibilidad se define como la medida del efecto de un factor de entrada (parámetro incierto X) en la respuesta de la salida (variable de salida Y). La herramienta es la obtención de los índices de sensibilidad recordando que una simulación de reservorios implica una compleja relación multi-variable no lineal. Estos análisis se realizan en las siguientes situaciones:

- Cuando muchos atributos inciertos son detectados.
- Para cuantificar la influencia de un parámetro o su inter-relación con otros en una respuesta determinada.
- Cuando la relación entre el fenómeno y los atributos del problema no resulta fácil de entender.

El análisis de sensibilidad global (ASG) es un análisis de impacto cruzado (segundo orden) de los parámetros inciertos en la variable en estudio. Este tipo de tratamiento implica el uso de una función de distribución de probabilidad para cada parámetro, ya que también se basa en el muestreo Monte Carlo. En consecuencia, este análisis requiere el uso de meta-modelos sofisticados y de buena calidad, lo que hace posible una investigación exhaustiva del dominio de variación y la evaluación de la inter-relación no lineal entre los parámetros considerados.

La segunda fase del Paso 1 consiste en definir los criterios de calidad para evaluar el grado de ajuste, es decir, seleccionar los pesos adecuados para cada término integrante de la ecuación de la Función Objetivo (FO). Las preguntas frecuentes en esta etapa son ¿qué pesos debo aplicar para series de medición de diferentes naturalezas?, ¿cuándo debo detener un proceso de mejora de un ajuste?, ¿cuál es el valor máximo aceptable de una FO compuesta?

Debemos tener en cuenta que siempre existen imprecisiones de medición y errores intrínsecos propios del modelo. Además siempre hay consideraciones subjetivas del analista respecto de su confianza en la capacidad pre-

dictiva del modelo. El problema se centra en definir un grado de importancia de esos errores que sea comparable con las mediciones de los diferentes tipos de variables consideradas en los diversos términos de la función objetivo compuesta.

Algunas preguntas que deben plantearse en esta etapa son ¿los componentes de la FO son coherentes con la visión del analista de lo que se debe tener en cuenta para considerar un ajuste de historia representativo?, ¿la FO definida tiene la capacidad de proporcionar resultados comparables con los que un analista tendría en la selección determinista de su mejor ajuste?

Para responder a estas preguntas es importante tener en cuenta los valores de las desviaciones estándar de los diversos componentes de la FO como una medida de la importancia de cada término de la función compuesta construida. Por ejemplo, dar la misma importancia a los ajustes de agua y presión. Esto es posible si los términos correspondientes en la FO tienen desviaciones estándar similares en las salidas calculadas para el grupo de modelos analizado. El impacto en la varianza de la respuesta también es el criterio utilizado cuando efectuamos un análisis de Sensibilidad Global al seleccionar los parámetros más influyentes para tener en cuenta en los pasos siguientes.

La fase final de este paso es la selección de los parámetros más influyentes. Es importante incluir el mayor número posible de parámetros y utilizar un amplio rango de variación para asegurar que los resultados obtenidos en las

simulaciones realizadas, según el diseño de experimentos elegido, se encuentren contenidos en una faja de variación acorde con la incertidumbre que se intenta representar. Si se diera el caso en el que la curva de los datos históricos no se encontrara dentro de esta banda o faja de dispersión inicial, es necesario volver al paso inicial y redefinir los parámetros inciertos, sea por la alteración de los límites o por la inclusión de nuevos parámetros de modo de garantizar que los registros históricos sean contenidos en la faja de incertidumbre inicial.

Los análisis de sensibilidad global se realizan en esta fase sobre las diferentes funciones objetivo con el fin de una clasificación inicial (*screening*) antes de comenzar el ajuste. Un diseño de experimentos basado en hipercubo latino (LHS), seguido por la construcción de superficies de respuesta no paramétricas (SRNP) es una combinación adecuada para el modelado del problema, como se explicará más adelante. El enfoque con ASG también ayuda en la detección de qué parámetros debemos optimizar, en primer lugar, y también si se deben tomar por separado o juntos en la estrategia de análisis (esta información se obtiene por los valores de los efectos de influencia cruzada entre los atributos). La interacción entre dos parámetros con poca influencia primaria independiente puede, con frecuencia, ser relevante en el intervalo de variación de una FO.

Un ajuste manual puede ser utilizado como punto de partida para el proceso de optimización de la FO. También podría ser utilizado para descartar valores posibles de los atributos para el posterior proceso de ajuste asistido.

## Paso 2. Ajuste de historia asistido con reducción de incertidumbre

En esta etapa, pueden llevarse a cabo tres tipos de enfoque de acuerdo con la disponibilidad de recursos y de tiempo.

### Camino 1. Optimización determinística

Esta aproximación consiste en la evaluación de la calidad de las SR representativas de la FO analizada. A partir de un proceso iterativo e interactivo se van adicionando corridas de confirmación para mejorar progresivamente la calidad de la SR, focalizando la zona de valores mínimos. Los parámetros que no tienen ninguna influencia en el ajuste, pero que podrían afectar al pronóstico deben ser incluidos para el análisis de comportamiento futuro. Este camino será desarrollado con más detalle.

- Ventajas: conceptualmente simple y con control del analista, requiere un costo computacional menor en comparación con otros enfoques.
- Desventajas: la mitigación de la incertidumbre de los parámetros utilizados en el ajuste se obtiene de filtros que actúan sobre meta-modelos aproximados.

### Camino 2. Aproximación probabilística

La consideración de un diseño de tipo probabilidad condicional o bayesiana se utiliza para obtener la dispersión *a posteriori* de la incertidumbre y para ser utilizada en las predicciones (Busby y Feraille, 2008). Este tipo de método de diseño adaptativo disminuye el número requerido de simulaciones para construir una superficie de respuesta precisa y predictiva en las áreas de espacio de muestreo

donde los valores de FO son bajos (región de soluciones aceptables). Esta aproximación de la FO seguidamente es usada en un algoritmo del tipo *Markov Chain Monte Carlo* (MCMC) para calcular la distribución a posteriori de los parámetros inciertos que permiten aproximar las respuestas calculadas a las mediciones de producción. Al final del período histórico, un nuevo plan de desarrollo se implementa y, por lo tanto, nuevos parámetros controlables pueden (y deben) añadirse al modelo generado.

- Ventajas: genera, en forma automática, el estrechamiento de los intervalos de incertidumbre de los atributos utilizados en el ajuste histórico y permite una optimización global del problema.
- Desventajas: gran consumo de tiempo computacional con la posibilidad de aparición de problemas de convergencia.

### Camino 3. Optimización determinística seguida de probabilística

Siguiendo las técnicas del camino 1, es posible obtener el mejor ajuste determinístico, que se puede utilizar como punto de partida para la aproximación bayesiana. Este enfoque permite caracterizar otras soluciones aceptables y obtener la incertidumbre remanente para la etapa de predicción.

- Ventajas: permite una convergencia más rápida y un mejor ajuste que el obtenido por el camino 2.
- Desventajas: consumo considerable de tiempo computacional. El ajuste inicial elegido al comienzo del cálculo ejerce una fuerte influencia, y da lugar a una focalización alrededor de un mínimo local del problema cuando, por su naturaleza, siempre existen más de una solución posible para resolver el ajuste (la FO tiene mínimos locales múltiples, pero solo uno de ellos se encuentra por la optimización determinística).

### Paso 3. Optimización del plan de desarrollo y predicción con incertidumbre a posteriori

Las decisiones en un plan de desarrollo se pueden clasificar en tres clases:

- Tipos de estrategias de desarrollo: cuándo, cómo y dónde aplicar la depleción primaria, inyección de agua, inyección de gas-agua alternada, la inyección de gas o CO<sub>2</sub>, etc.
- Tipos de tácticas para los pozos: la selección del tipo y la trayectoria de pozos, los objetivos, el espaciamiento, los diámetros de cañerías, los sistemas de elevación, el tipo de terminación, etc.
- Tipos de tácticas operacionales: la tasa de reemplazo de líquidos en condiciones de fondo, el balance entre las zonas bajo recuperación secundaria, la tasa de llenado del casquete de gas, el cronograma de terminaciones, las restricciones de presiones de fondo y de cabeza de pozos productores e inyectores, el límites de caudales de producción y de inyección por zonas, etc.

En esta fase también se pueden distinguir tres tipos de enfoques para el tratamiento de este problema:

- Enfoque 1: optimización determinística de la respuesta por medio de la variación de los parámetros de control usando el mejor ajuste de historia.

- Enfoque 2: toma de decisión con incertidumbre donde varias opciones de desarrollo disponibles se ponen a prueba, bajo un único modelo con incertidumbre, para escoger la solución más adecuada con el contexto (condicionamientos) del problema.
- Enfoque 3: optimización con incertidumbre. En este caso, se proporciona una respuesta a ser optimizado (modelo con incertidumbre), teniendo en cuenta parámetros controlables y nuevos parámetros de incertidumbre no fueron considerados en el Paso 2 (ajuste de historia). Diferentes escenarios pueden ser previstos para evaluar la estrategia de desarrollo y las tácticas asociadas con la operación relacionada. Entre ellos, se muestra los siguientes ejemplos:
  - Escenario 1. Optimización determinística o selección seguida de decisión con incertidumbre.

Diversas estrategias de desarrollo y una sola táctica de distribución y tipo de pozos (espaciamiento y geometría) se establecen para todas las estrategias con las operaciones optimizadas de forma determinista (utilizando el mejor ajuste histórico). Todos los casos son corridos en meta-modelos con incertidumbre para seleccionar el mejor plan de desarrollo. Una vez que se elige la mejor estrategia, tácticas diferentes en relación con la geometría y el espaciamiento pueden abordarse; y nuevamente se selecciona el mejor conjunto de soluciones. Este escenario es muy costoso en tiempo computacional.

- Escenario 2. Optimización probabilística o selección seguida de optimización con incertidumbre y posterior toma de decisión.

Este escenario es considerado el más robusto. Son definidas diversas estrategias de desarrollo para cada modelo ajustado y varias tácticas para los pozos. Para cada una de las combinaciones modeladas, las estrategias de operación con incertidumbre son optimizadas para permitir la comparación de los resultados. En este enfoque se puede incluir el caso en el que son parametrizadas algunas tácticas de pozo (por ejemplo, las ubicaciones de nuevos pozos) y podrían ser abordadas en la optimización con incertidumbre de modo separado del resto de la operación.

Escenarios como los que se presentaron pueden imaginarse con diversas combinaciones de optimización determinística, la toma de decisiones en condiciones de incertidumbre y optimización con incertidumbre. Los escenarios anteriores se utilizan como ejemplos de lo que puede ser realizado.

## Modelo

Se utilizó un modelo de simulación numérica del tipo *Black Oil* con aproximadamente 100.000 bloques para re-






Figura 2. Imagen 3D del modelo de simulación (sistema de celdas). La propiedad mostrada es el espesor poroso con petróleo (metros).

presentar el bloque principal de producción. El tamaño de la grilla es de 105 x 75 x 12. Las capas 11 y 12 representan básicamente el acuífero de fondo existente (Figura 2).

Se colocaron varias fallas en el modelo, la mayoría verticales, con base en la interpretación sísmica, con multiplicadores para considerar la incertidumbre en la comunicación entre los bloques. Se utilizó una relación global de permeabilidades kv/kh. El acuífero se encuentra en las capas inferiores, reforzados con una representación analítica *Carter Tracy*. Un único conjunto de curvas de permeabilidad relativa y un solo contacto agua-petróleo se consideró para el bloque principal de producción. El modelo cuenta con 29 pozos productores y 5 pozos inyectores (Figuras 3a y 3b).

## Flujo de trabajo

El propósito de este estudio es aplicar el Paso 1 (sensibilidad y el análisis inicial de incertidumbre) y el Camino 1 del Paso 2 (ajuste asistido de historia para reducir la incertidumbre mediante optimización determinista), mientras que la aplicación del Paso 3 (optimización del plan de

desarrollo con incerteza remanente) se encuentra fuera del alcance de este análisis.

El objetivo general del trabajo es hacer un ajuste de historia (AH) teniendo en cuenta la incertidumbre inicial de los parámetros críticos identificados por medio de un análisis de sensibilidad global. Se busca obtener una mitigación posterior de los rangos de variación de estos parámetros, reduciendo al mínimo las funciones objetivo elegidas, que cuantifican la separación de las variables calculadas respecto de sus valores históricos. Por último, se tratará de obtener un pronóstico probabilístico de producción basado en el estrechamiento de los rangos de variación de los parámetros inciertos.

Los procedimientos generales para cumplir esos objetivos son listados a continuación, pero el orden y la elección de uno u otro dependen muchas veces del programa comercial utilizado.

1. Inicialmente es importante pre-procesar la información recopilada y revisar todos los datos de entrada (estática y dinámica) y validar o eliminar todas las mediciones cuestionables.
2. Recopilar y realizar controles de calidad de las respuestas de simulación (presiones y producciones de agua y de petróleo).
3. Establecer criterios para la cuantificación de la medición de la calidad del ajuste de historia (creación de la función objetivo).
4. Identificar los parámetros inciertos, su posible rango de variación y las distribuciones *a priori* que los representan.
5. Seleccionar el diseño experimental para combinar con todos los parámetros inciertos y el modelo de superficie de respuesta para el análisis global de sensibilidad.
6. Analizar la sensibilidad de los parámetros para la presión y la producción de petróleo y de agua, y su efecto en la calidad del ajuste de historia.
7. Seleccionar los parámetros más críticos para iniciar el proceso de ajuste asistido de historia.
8. Realizar un diseño experimental más detallado teniendo en cuenta únicamente los parámetros críticos seleccionados.





Figura 3. Imagen 2D del tercer nivel, (a) planta (b) corte este-oeste. La propiedad representada es la permeabilidad horizontal (mD).

9. Obtener la banda de dispersión de incertidumbre *a priori* del comportamiento del reservorio mediante propagación de simulaciones Monte Carlo (MC) sobre las superficies de respuesta para cada variable de ajuste, sin tener en cuenta los datos de producción. Más adelante, esta banda permitirá referenciar la magnitud de la reducción de la incertidumbre obtenida.
10. Realizar iterativamente simulaciones de flujo adicionales dirigidas a mejorar la calidad de la SR en torno de la zona de mínimos de la función objetivo (para la herramienta A) o realizar un proceso de optimización para encontrar la combinación de parámetros que minimizan la función objetivo (en la herramienta B).
11. Determinar las distribuciones de probabilidad *a posteriori* con rangos más angostos para los parámetros críticos.
12. Identificar nuevos parámetros que podrían afectar solo el período de predicción.
13. Seleccione el diseño experimental final que incluye los parámetros críticos y sus distribuciones posteriores asociadas. Incluir nuevos parámetros que no se utilizaron para el ajuste de historia, pero que podrían afectar el período de pronóstico y realizar una nueva propagación MC sobre las superficies de respuesta.
14. Obtener el análisis final de la incertidumbre.
15. Determinar las distribuciones de probabilidad de las variables de interés en varios tiempos característicos elegidos en las curvas de predicción.
16. Obtener las curvas representativas de percentiles característicos  $P_{10}$ ,  $P_{50}$  y  $P_{90}$ .
17. Construir modelos de flujo reales (a partir de las combinaciones de parámetros) correspondientes a los casos de los percentiles característicos  $P_{10}$ ,  $P_{50}$  y  $P_{90}$  para todos tiempos considerados en el paso anterior simultáneamente. Estos modelos son extraídos usando un filtro sobre las superficies de respuestas conjuntas, válidas y vinculadas en esos tiempos múltiples entre todos los lanzamientos probabilísticos MC disponibles.

## Parámetros seleccionados

Los parámetros inciertos considerados y sus límites y valores centrales son mostrados en la tabla 1.

Nombre	Min	Max	Valores centrales	Descripción
AQ100 y AQ200	0	0.2	0.0715 y 0.0657	Reducción de transmisibilidad en la conexión de los acuíferos CRP-100 y CRP-200
AQRAD	500	5000	1000	Radio equivalente del reservorio para el cálculo del acuífero analítico
AQRPOR	0.2	0.4	0.3	Variación de la porosidad del acuífero analítico
CPOR	9.00E-05	1.10E-04	1.00E-04	Compresibilidad de la formación
MULTF (n I/S)	0.1	1	Media 0.185	Multiplicadores para reducción de transmisibilidad de fallas
MULTPI	0.5	2	1	Multiplicadores de IP para pozos perforados. Utilizados en la etapa de pronóstico.
PERMI	0.8	1.8	1.3	Multiplicador de la permeabilidad horizontal
PERMK	0.005	0.05	0.01438	Multiplicador de la permeabilidad vertical
TK	"TK_1", "TK_2", "TK_3"		TK_3	Distribución de la transmisibilidad vertical nula variando según valores de <i>cutoff</i> en mapas NTG (discreto)
WOC	2754	2758	2754	Contacto Agua-Petróleo
krow_max	-	-	0.79	Parámetros de permeabilidad relativa por Corey
krw_max	0.2	0.5	0.3	
no	0.5	2.5	1.5	
nw	3.5	6.5	5	

Tabla 1. Parámetros con incertidumbre considerados en el estudio.

## Diseño de experimentos

Para los análisis mencionados en el flujo de trabajo, fueron realizados diversos diseños experimentales con Hiper-cubo Latino (LHS), en general se destacan las herramientas comerciales utilizadas con diferentes tipos de diseño de experimentos. La selección del diseño es importante cuando se trabaja con modelos de superficie de respuesta. Entre los tipos disponibles, se destaca la técnica LHS que ha sido ampliamente usada y recomendada en estudios que envuelven diseños de experimentos (Zubarev, 2009; Bravtold y Begg, 2010). Esta técnica asegura que se investigue todo el espacio de muestreo del problema (*space filling*) con el empleo de un "muestreo estratificado", a fin de disminuir el número de simulaciones requeridas sin reducir la calidad de superficie de respuesta. Este tipo de diseño genera un conjunto de puntos que, a pesar de ser aleatorios, permite un muestreo del modelo teniendo en cuenta la distribución asociada informada para cada parámetro incierto, concentrándose en las zonas con más probabilidad de ocurrencia.

Por ejemplo, consideremos  $n$  experimentos (simulaciones) y dos parámetros inciertos con distribuciones de probabilidades distintas, el primero triangular y el otro normal, como se muestra en la figura 4. Sobre la base de la distribución de probabilidad acumulada para ambos parámetros se proponen  $n$  puntos uniformemente distribuidos desde la discretización de cada distribución que cumplen con las siguientes condiciones:

- Los valores muestreados al azar se combinan para definir los experimentos de una única muestra de la misma manera que en una simulación de Monte Carlo.
- Las muestras se definen un número de veces constantes para cada rango discreto sin ser repetido en experimentos sucesivos, y asegura así un muestreo de todo el intervalo de búsqueda considerado para el atributo.
- Los valores muestreados tienden a concentrarse alrededor de la mayor probabilidad, que indica la característica de la dependencia según el tipo de función de distribución asociada a cada parámetro.

Cuando se trabaja con la herramienta B, algún tipo de atención es necesario al emplear el diseño experimental hiper-cubo latino. Aunque el paso que combina los parámetros para crear los experimentos sigue la metodología




Figura 4. Esquema del diseño de experimento Hipercubo Latino con dos parámetros (SPE 12485-ZUBAREV, 2009).

descripta anteriormente, los parámetros no se muestrean en consecuencia. En la herramienta B se utilizan normalmente entre 3 y 7 valores para cada parámetro, que no pertenecen a particiones equiprobables.

Este tipo de muestreo funciona bien con técnicas de diseño experimentales clásicos, pero puede ser insuficiente para representar con fenómeno altamente no lineal (el ajuste histórico) o parámetros con distribuciones no uniformes. El valor y la cantidad de las muestras se pueden ajustar manualmente en la herramienta B para seguir el muestreo hipercubo latino. Con un alto número de muestras (la herramienta A lo realiza en forma automática) puede tornarlo poco práctico, pero entre 7 y 13 muestras parecen suficientes para representar la mayoría de los problemas. En general, para este diseño experimental, las herramientas muestrean cualquier valor dentro de la variación de cada parámetro para construir los diferentes casos.

Este tipo de limitaciones normalmente encontradas en los softwares comerciales no son inmediatamente evidentes, pero pueden tener un impacto significativo en los resultados finales. Resulta fundamental entender ese tipo de inconvenientes que normalmente se van suscitando en la aplicación de una metodología.

### Respuestas analizadas

Nos concentraremos en el ajuste de las respuestas calculadas de petróleo y agua calculados en diferentes tiempos durante la simulación, la producción acumulada de petróleo y el agua en el instante final de la simulación, y la presión promedio del yacimiento en diferentes momentos. La presión media y los caudales de agua y petróleo se utili-

zan para evaluar la calidad ajuste de historia. Se observan acumuladas para evaluar el rango de dispersión generado por la incertidumbre existente en el problema en estudio.

### Definición de la Función Objetivo

Para evaluar la calidad del ajuste de historia (AH), debe establecerse una función objetivo (FO). La herramienta A usa una opción llamada *Objective Function*, definida por la siguiente ecuación:

$$FO(x) = \sum_{i,j,k} \omega_i \omega_j \omega_k \frac{(Y_{i,j,k}^{obs} - Y_{i,j,k}^{sim})^2}{n_{obs}} \quad (1)$$

donde:

$\omega$  = corresponde a diferentes tipos de pesos (local, global, temporal) de cada término de la ecuación.

$obs$  = denota los datos históricos observados.

$sim$  = denota los datos simulados.

$n$  = cantidad de valores medidos.

Para generar una FO compuesta representativa teniendo en cuenta como objetivos los caudales de producción de agua y petróleo y la presión media del bloque, con las tres magnitudes participando con la misma importancia, es necesario modificar los pesos de cada uno de estos conjuntos de datos para garantizar una contribución balanceada, en lo referido a los valores de la variancia correspondiente a cada uno de ellos. La desviación estándar es uno de los indicadores más utilizados para evaluar el grado de participación de cada variable en la FO. A partir del ajuste de los pesos en los datos en cada FO es posible obtener desviaciones estándar comparables para cada respuesta analizada en forma independiente.

Con los pesos originalmente utilizados por el programa, en el ejemplo, el caudal de agua sería el objetivo principal, mientras que los errores de los ajustes de caudal de petróleo y la presión no necesariamente van a ser reducidos. Por lo tanto, es importante y recomendable antes de calcular una FO compuesta, observar y analizar con el criterio explicado los pesos de cada magnitud componente.

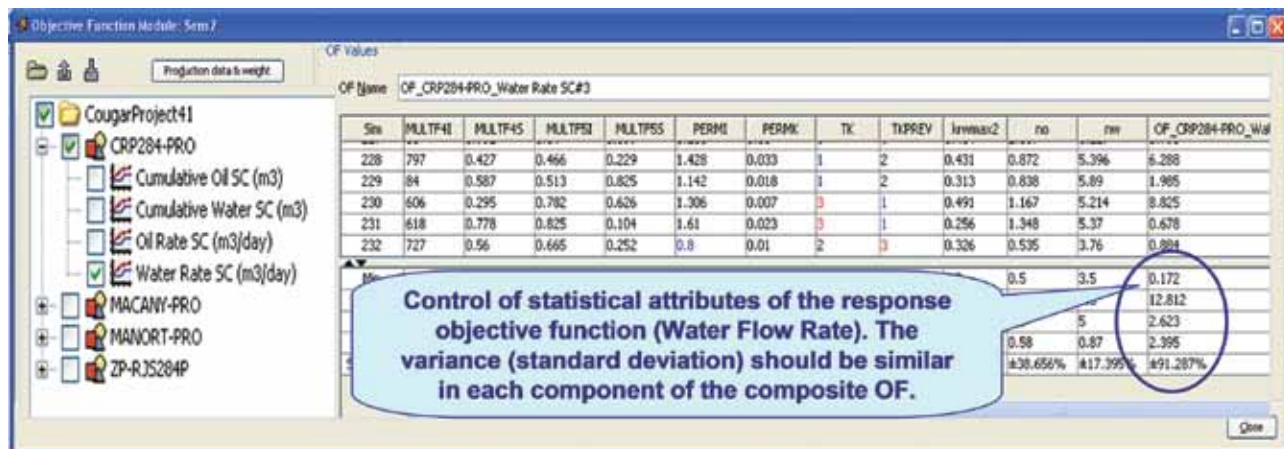


Figura 5. Análisis estadístico y ajuste de pesos para un componente de la FO Compuesta (caudal de agua).



Una vez que los pesos fueron alterados, las desviaciones estándar de cada contribución de la FO deben ser verificadas. Estos valores independientes deben ser comparables o semejantes con el objetivo de otorgar la misma relevancia en cada término integrante de la función. En el caso de la presión, el intervalo de confianza sugerido por el programa es de aproximadamente 22 kgf/cm<sup>2</sup> (surgido de considerar el 10% respecto del valor medio). Sin embargo, el peso de esta variable es aún insuficiente para tener significancia en el proceso de ajuste de los datos históricos de la presión contrastado, por ejemplo, con el agua. Para ello, los intervalos de confianza fueron modificados por cada respuesta:

- Presión: fue disminuido de 22 para 7kgf/cm<sup>2</sup>
- Agua: fue aumentado de 50 para 200m<sup>3</sup>/d
- Petróleo: fue reducido de 500 para 200m<sup>3</sup>/d

En la figura 5 se ilustran los valores de los parámetros estadísticos obtenidos en el cálculo de la porción de la FO correspondiente al caudal de la variable agua producida. También se calculan los otros dos componentes en forma independiente, y finalmente la FO compuesta teniendo en cuenta las tres respuestas en conjunto.

En la herramienta B, la función objetivo para el ajuste de historia es definida de forma un poco diferente, como se puede deducir por la fórmula proporcionada por el programa (Ecuación 2):

$$Q_i = \frac{1}{N(i)} \sum_{j=1}^{N(i)} \frac{\sqrt{\sum_{t=1}^{T(i,j)} (Y_{i,j,t}^s - Y_{i,j,t}^m)^2}}{NT(i,j) \cdot Scale_{i,j}} \cdot 100\% \cdot tw_{i,j} \quad (2)$$

La primera diferencia que se destaca es la raíz cuadrada que se aplica a la suma de los errores al cuadrado en cada serie histórica considerada. Esto da lugar a un crecimiento más lento de la FO cuando el ajuste empeora. Para la FO de una sola variable, no hay mucha diferencia, pues los mínimos de la función (el mejor ajuste) permanecen sin transformaciones. No obstante, cuando se calcula una FO compuesta mediante la adición de diferentes porciones, el efecto de aplicar la raíz cuadrada a cada término por separado puede hacer que los mínimos de la FO compuesta no se localicen exactamente en la misma combinación de parámetros que la obtenida con la formulación de la ecuación 1. Finalmente, el hecho de trabajar con pesos similares, en ambas herramientas, a fin de dar la misma importancia a la serie de datos, tiende a minimizar este problema. Además, al ser utilizada en el análisis una región alrededor del mínimo, no solo en un único punto, esta discrepancia tiende a disiparse.

Otra diferencia significativa está en la definición de los pesos FO. Ambas herramientas analizadas calculan un peso predeterminado para cada FO ( $scale^{i,j}$ , para el caso de la B). Sin embargo, en este caso, el usuario no tiene acceso a este valor, solo puede establecer un multiplicador por separado ( $tw_{i,j}$ ). Asimismo, no es posible definir pesos diferentes para cada tiempo de las series temporales. La definición del peso *default* es bastante compleja y en muchos

casos puede llevar a resultados más satisfactorios, ya que tiene en cuenta la variación máxima de la serie histórica ( $\Delta Y_{i,j}^m$ ) en lugar de su valor medio, mediante las siguientes reglas (ecuación 3):

$$Scale_{i,j} = \max \left\{ \begin{array}{l} \Delta Y_{i,j}^m + 4 \cdot Merr_{i,j} \\ 0.5 * \min(|\max(Y_{i,j,t}^m)|, |\min(Y_{i,j,t}^m)|) + 4 \cdot Merr_{i,j} \\ 0.25 * \max(|\max(Y_{i,j,t}^m)|, |\min(Y_{i,j,t}^m)|) + 4 \cdot Merr_{i,j} \end{array} \right. \quad (3)$$

El término  $Merr_{i,j}$  es el error de medición de cada variable y será nulo en este tratamiento. La primera forma se refiere a la variación máxima de la serie, la segunda al valor absoluto más bajo del valor absoluto más grande de la serie. En la figura 6 se ilustran estos términos para la serie histórica de presión.

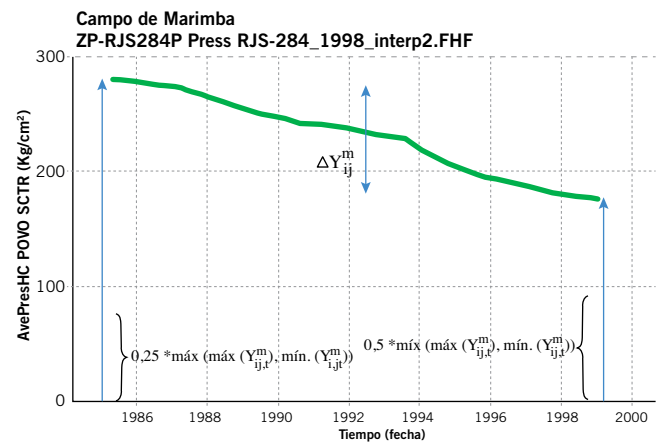


Figura 6. Definición de los tres términos del factor de escala en la herramienta B para la serie temporal "presión estática".

Con todo, es posible tener malos resultados, especialmente en los casos en los que el promedio de la serie es mucho mayor que su variación máxima y el peso asume la segunda (o tercera) forma. En el caso analizado, los pesos *default* provocaron que la serie de petróleo sea de poca influencia en la FO compuesta. En la figura 7a se exhibe el valor de las FOs para cada combinación. Para obtener valores satisfactorios fue necesario calcular manualmente cuál es el

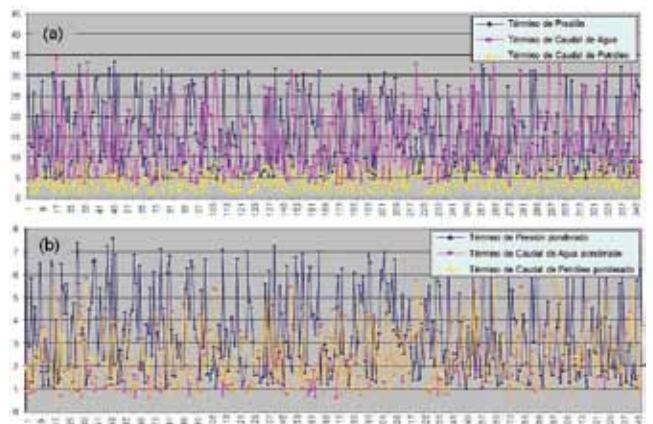


Figura 7. Valor de los componentes individuales de la FO compuesta: (a) con el uso de los "pesos" default y (b) alterando la ponderación inicial.

peso que la herramienta aplicó internamente para cada serie y utilizar el recurso del peso que el usuario puede definir ( $tw_{i,j}$ ) para, simultáneamente, solaparlos o cancelarlo y definir un nuevo peso igual al usado con la herramienta A. En la figura 7b se muestra como los valores de los tres términos por separado de las FOs, ya ponderados, tienen un desvío estándar más próximo, debido a los nuevos pesos calculados. Nótese que, aunque los pesos son iguales, el FO compuesto es todavía diferente en los dos programas, debido a la presencia de la raíz cuadrada en su formulación. Esto explica en parte por qué los resultados en cada caso no son idénticos. Una vez más, la comprensión de los módulos aparentemente similares, disponibles en diferentes aplicaciones, es esencial para la interpretación de los resultados.

## Superficies de respuesta

La superficie de respuesta (SR) es un tipo de modelo aproximado de la respuesta dinámica de un modelo de simulación. Si bien, no es necesario que el SR reemplace el simulador en cualquier caso, cuando consideramos varios parámetros inciertos que interactúan de forma no lineal, la complejidad y el tiempo de cálculo exige recurrir al uso de modelos aproximados (*proxy models*) de las respuestas de interés, matemáticamente más simples, que aseguran resultados confiables en las regiones próximas a los valores mínimos de la función objetivo.

Este tipo de aproximación puede ser realizado por medio de diferentes modelos, como regresión con polinomios, uso de la técnica de interpolación gaussiana de *Kriging*, redes neuronales, etc. Una SR tiene que representar el comportamiento no lineal de un modelo real mediante un modelo simplificado de fácil aplicación (Zubarev, 2009). Un modelo de regresión polinomial puede ser representado con la siguiente ecuación:

$$y(x) = \beta_0 + \sum_{i=1}^{n_d} \beta_i x_i + \sum_{i=1}^{n_d} \sum_{j>1}^{n_d} \beta_{ij} x_i x_j + \sum_{i=1}^{n_d} \beta_{ii} x_i^2 \quad (4)$$

donde:

$x$  = vector de las variables de entrada

$x_i$  = término lineal

$x_i x_j$  = término cruzado

$x_i^2$  = término cuadrático

$\beta_0, \beta_i, \beta_{ij}$  e  $\beta_{ii}$  = coeficientes de regresión para los términos lineales, cruzados y cuadráticos, respectivamente.

El análisis multi-respuesta solo está disponible en la primera herramienta y facilita la creación de SRs en diferentes tiempos de interés en forma automática. Este tipo de análisis es importante para evaluar cómo las incertidumbres críticas interactúan y se propagan en el tiempo. Cada FO es representada por una SR, creada a partir de los casos de simulación corridos. En la figura 8 se ilustra un ejemplo de seis SRs generadas para una producción acumulada de petróleo ( $Np$ ). Por lo tanto, cada línea de referencia vertical representa los resultados probabilísticos explorados con una SR, y la distancia entre el punto superior e inferior representa la variabilidad total de la FO en cada tiempo elegido. En cada uno de ellos, es posible identificar el valor de  $Np$  que corresponde a los percentiles  $P_{10}$ ,  $P_{50}$  e  $P_{90}$ . Esto significa que existe una combinación de atributos inciertos de entrada de

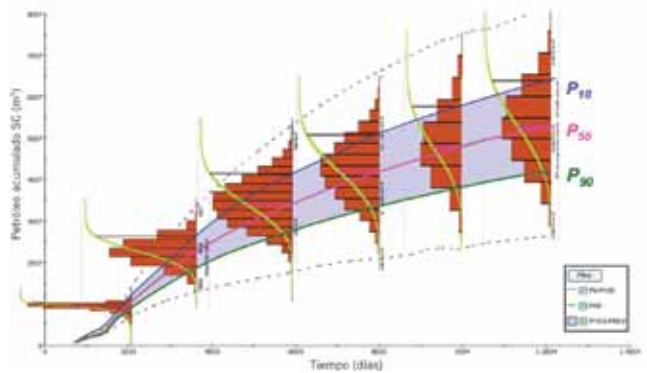


Figura 8. Ejemplo de la dispersión de una respuesta analizada probabilísticamente en diferentes tiempos.

la SR que representa cada uno de estos percentiles y que son diferentes entre sí, no necesariamente vinculada a un único modelo de simulación o combinación de parámetros. Es decir, la evolución con el tiempo de un percentil X determinado no tiene, ni debe corresponder a un modelo o combinación de parámetros singular. El desafío es encontrar una combinación más próxima que asegure cumplir con la condición del valor percentil X *versus* tiempo. Esto será tratado más adelante en este trabajo.

## Superficies de respuesta no paramétricas (SRNP)

Luego, son creadas las superficies de respuesta no paramétricas para cada variable. Si bien este tipo de construcción puede consumir bastante tiempo, cabe señalar que las nuevas versiones de los programas son cada vez más veloces y más robustas.

Es importante entender primero qué es una regresión paramétrica y no paramétrica. La regresión paramétrica es posible cuando *a priori* se asume o conoce el tipo de relación funcional entre las variables dependientes e independientes. A pesar de que tenga parámetros cuyos valores son desconocidos pueden ser estimados a partir de un conjunto de entrenamiento (valores de la respuesta conocida). En este caso, la regresión corresponde al proceso de aproximación de un polinomio lineal o cuadrático a diferentes valores de una respuesta surgidos de experimentos (combinaciones diferentes de atributos inciertos que generan la corridas de simulación del estudio) para representar una superficie de esa respuesta de modo paramétrico (SR).

Por otra parte, una regresión no paramétrica se caracteriza por la ausencia total o casi total de un conocimiento *a priori* acerca de la forma de la función que se está pretende estimar. Consecuentemente, incluso si la función es estimada a partir del conjunto de parámetros libres, el conjunto de las formas que la función puede tener es muy amplio (clase de funciones o realizaciones estocásticas que el estimador basado en un método de iteración espacial puede predecir). Como resultado, puede haber un gran número de parámetros (en comparación con el número de datos de entrada/salida para el cálculo), que ya no admite una interpretación física aislada.

Las superficies de respuesta no paramétricas (SRNP) se basan en la aplicación del método de *Kriging*, creado por Daniel G. Krige (1952) para impulsar el desarrollo y la opti-



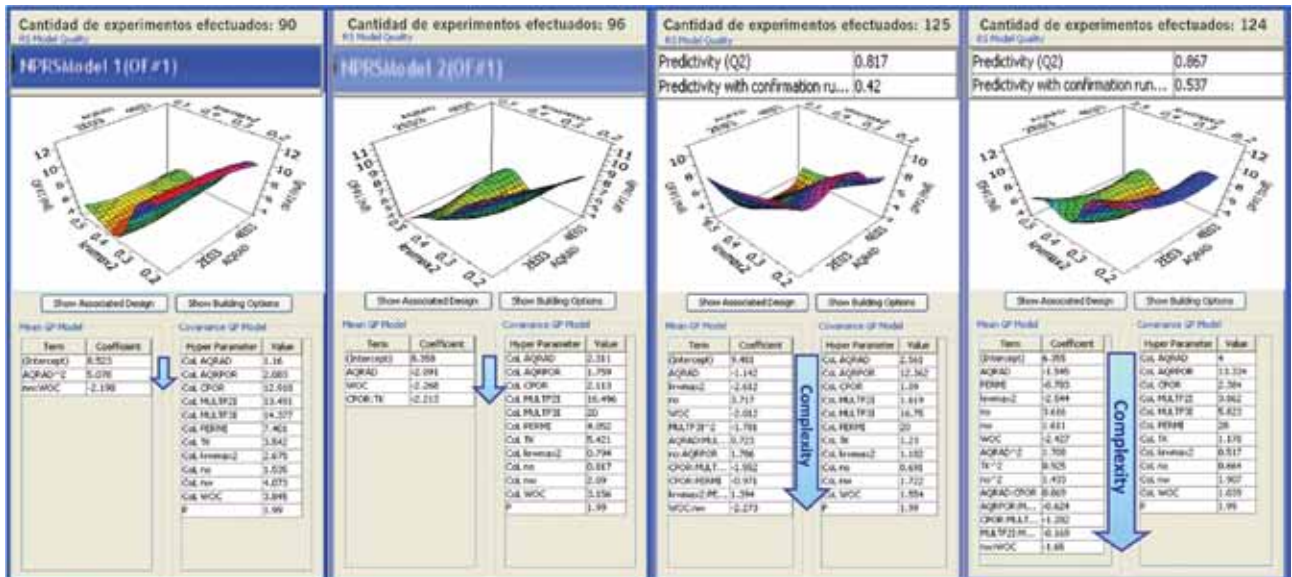


Figura 9. Ejemplo de resultado de mejora progresiva de las SRs. Nótese el incremento de la complejidad del modelo con el aumento de las iteraciones.

mización de la producción de minas de oro en Sudáfrica a partir de diversas regresiones de las varianzas direccionales para cuantificar espacialmente las estimaciones de la reserva y rendimiento del mineral. Este método inicialmente empleado en minería fue introducido en la geología del petróleo por Matheron (1969, *Le Centre de Geostatistique de l'École des Mines de Paris*) teniendo una amplia difusión en el área de la geoestadística, actualmente es ampliamente extendido a otras áreas con mejoras y adaptaciones. Este procedimiento asume la construcción de la SR como un proceso gaussiano (PG) que se caracteriza por el cómputo de una estructura de media y covarianza y es un estimador lineal imparcial.

La calidad de las SRNP construidas en el paso inicial es del orden de 0,6 ( $Q_2 = 0,586$  adicionando las corridas de confirmación), lo cual expresa que el modelo todavía no es predictivo o demasiado confiable para continuar con la metodología (Figura 9).

El propósito de la metodología propuesta es evaluar la calidad del ajuste, por lo que es esencial tener confianza en las SRs generadas para tal fin. Es importante que representen el comportamiento dinámico del modelo, principalmente en los casos en que un buen ajuste es obtenido. En los casos en que los modelos no se encuentran bien ajustados con los datos de producción no es necesaria una extrapolación estricta de la superficie de respuesta.

Resulta preciso señalar que la versión de investigación de la herramienta A (su prototipo está disponible solo para los patrocinadores del JIP) tiene una función llamada "superficie de respuesta adaptativa". Este módulo aborda un nuevo método iterativo de diseño experimental jerárquico para mejorar gradualmente la calidad de los experimentos RS, que se añaden en la siguiente repetición, seleccionados automáticamente en las proximidades de las posibles soluciones del problema inverso. Estas soluciones son exploradas utilizando el método de simulación por medio de un diseño de Cadena de Markov Monte Carlo (MCMC) siguiendo un esquema de probabilidad condicional bayesiana. Esto significa que, para cada iteración, solo unos pocos nuevos experimentos se eligen a partir de la distribución posterior de las mejores soluciones calculadas en la iteración anterior (Emerick y Reynolds, 2010). El objetivo final

de este método es obtener una distribución de la incertidumbre *a posteriori*, usando los datos dinámicos disponibles que no se encuentran influenciados por los errores propios de la SR. El método concentra la localización de las corridas de confirmación en la región de interés maximizando la función de verosimilitud (máxima probabilidad de encontrar a la zona de FO mínima), que servirán de base para la construcción de una nueva superficie de respuesta en el paso siguiente. Este proceso es repetido automáticamente mediante un esquema iterativo hasta alcanzar una determinada calidad de la superficie de respuesta preestablecida.

Cuando este recurso no está disponible, el proceso puede ser efectuado en forma manual con ciertos cuidados. A partir de la SRNP de las funciones objetivo referentes del ajuste global, se obtuvieron corridas de confirmación en las regiones donde la SRNP tiene buena calidad de ajuste, es decir, nuevas simulaciones son seleccionadas en la zona del espacio de muestreo que se corresponden con bajos valores de la FO y posteriormente son evaluadas en esos nuevos puntos. Fueron seleccionados en cada paso, algunos diseños posibles con menores cantidades de FO compuesta que a continuación son definidos como nuevas corridas de confirmación para mejorar la calidad de superficie de respuesta en las regiones en torno a estos valores. Si la respuesta de SRNP es aceptable, podemos confiar en el modelo predictivo y se continúa para el siguiente paso. Caso contrario, una nueva SR es construida teniendo en cuenta los resultados de las nuevas corridas de confirmación. De esta forma son seleccionadas y añadidas nuevas corridas de simulación, y el proceso se repite hasta que tengamos suficiente confianza en la SR. Esto significa que el indicador de calidad  $Q_2$  tenga un valor por encima de una referencia mínima escogida. En el caso estudiado fue obtenida una superficie de respuesta con el indicador  $Q_2$  igual a 0,929 luego de la quinta iteración.

En la figura 9 se presenta la evolución de la SR (después de cuatro iteraciones). Note que las simulaciones de confirmación se concentran en las regiones donde los valores de FO son bajos. La SR se utilizará en las etapas posteriores de la evaluación de los posibles modelos ajustados. ■

Fin de la Primera Parte. La Segunda Parte, en Petrotecnia de diciembre.