

La toma de decisiones para intervenir pozos mediante técnicas de inteligencia artificial

Pablo H. Ibargüengoytia, Uriel A. García y Alberto Reyes

Instituto de Investigaciones Eléctricas, Cuernavaca, Morelos, México. Correo: pibar@iie.org.mx

Resumen

Se presentan los resultados de un proyecto de investigación realizado bajo el Fondo Sectorial SENER Hidrocarburos, en consorcio con el Instituto Mexicano del Petróleo (IMP) y el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE). El proyecto fue “Métodos y Técnicas de Inteligencia Computacional y Minería de Datos para la Toma de Decisiones en Exploración de Campos Maduros”. La aportación del Instituto de Investigaciones Eléctricas consistió en el desarrollo de un sistema para decidir la forma óptima de intervenir ciertos pozos petroleros a fin de incrementar la producción en los pozos productores. El sistema se basa en modelos gráficos probabilistas desarrollados en el área de la inteligencia artificial. Los modelos gráficos probabilistas, específicamente las redes bayesianas y los diagramas de influencia, son métodos desarrollados para trabajar con incertidumbre o con aplicaciones donde los modelos analíticos no funcionan, son caros o difíciles de construir. La propuesta de selección de pozos consiste en dos pasos. Primero, la construcción de mapas de interconexión entre pozos en forma de redes bayesianas, y segundo la conversión de esos mapas en diagramas de influencia para la toma de decisiones. Las redes bayesianas codifican las relaciones probabilistas entre las variables de alguna aplicación. Están basadas, como su nombre lo dice, en el teorema de Bayes que relaciona las hipótesis con las evidencias de algún proceso. En este caso, se asume que hay una relación entre la intervención de pozos inyectores y la producción de pozos productores. Esa relación se encuentra al revisar los archivos de datos históricos de inyección y producción. Se utiliza alguno de los múltiples algoritmos de aprendizaje automático de redes bayesianas para encontrar estos mapas. Por su parte, los diagramas de influencia son una extensión a las redes bayesianas donde además de nodos de variables se tienen nodos de decisión y nodos de utilidad. Los nodos de decisión codifican la cantidad de inyección que puede aceptar un pozo y los nodos de utilidad calculan el beneficio de tomar cierta decisión. Con este mecanismo, se logra la definición de la decisión óptima de inyección. Este artículo propone aplicar este trabajo en campos geotérmicos, donde se podría optimizar la inyección para mejorar la producción de vapor y la generación de energía eléctrica.

Palabras clave: Pozos inyectores, pozos productores, redes bayesianas, diagramas de influencia, modelos probabilistas.

Decision making to intervene wells by using artificial intelligence techniques

Abstract

This paper presents the results of a research project supported by the Fondo Sectorial SENER-Hidrocarburos, in partnership with the Mexican Petroleum Institute (IMP) and the National Institute of Astrophysics, Optics and Electronics (INAOE). The project was “Methods and Techniques of Computational Intelligence and Data Mining for Decision Making in Mature Fields Exploration”. The contribution of the Instituto de Investigaciones Eléctricas was the development of a system to decide the best intervention of oil wells so that the production increases. The method used is based on probabilistic graphical models, developed in the area of artificial intelligence. Probabilistic graphical models, specifically Bayesian networks and influence diagrams, are methods developed for working with uncertainty or applications where analytical models do not work, are expensive or difficult to build. The proposal for selecting wells to be intervened consists of two steps. First, the construction of

interconnection maps between wells as Bayesian networks and second, the conversion of these maps on influence diagrams for decision making. Bayesian networks encode probabilistic relationships between variables in any application. They are based, as its name implies, on the Bayes theorem that relates the hypothesis with evidence of some process. In this case, it is assumed that there is a relationship between the intervention of injection wells and the behavior of production wells. That relationship is found analyzing the historical data files of injection and production. One of the many machine learning algorithms available for Bayesian networks is used to find these maps. On the other hand, influence diagrams are an extension of Bayesian networks where besides the chance nodes, decision nodes and utility nodes are included. Decision nodes encode the injection volume that a well can accept and utility nodes calculate the benefit of taking certain decision. With this mechanism, the definition of the optimal decision injection is achieved. This paper proposes to implement this methodology in geothermal fields where injection in wells can be optimized to maximize the steam production and the power generation.

Keywords: Injection wells, production wells, Bayesian networks, influence diagrams, probabilistic models.

1. Introducción

La industria del petróleo se enfrenta actualmente a una nueva era donde la tecnología se ha convertido en una parte esencial de la misma, debido al desarrollo de herramientas informáticas que en las últimas décadas han tenido avances muy exitosos.

La producción de petróleo se puede dividir en tres etapas diferentes. La primera de ellas se conoce como recuperación primaria. En esta etapa, el flujo de petróleo y gas fluye a la superficie de forma natural por la propia presión del depósito. Una vez que la producción de la etapa de recuperación primaria alcanza su pico, normalmente se inyecta agua, aire, CO₂ o nitrógeno en el yacimiento a fin de mantener un nivel de presión adecuado y permitir que el aceite siga fluyendo en superficie. Cuando esto ocurre el depósito se conoce como un campo ‘maduro’, mientras que el aumento de la presión artificial se conoce como recuperación secundaria. Inevitablemente, después de un tiempo, incluso con el aumento artificial de la presión la producción disminuirá. En algunos campos se inyecta calor o productos químicos para cambiar las propiedades del petróleo y volverlo menos denso, para que fluya más fácilmente. Esta estrategia se conoce como recuperación terciaria (COT, 2007).

Durante la recuperación primaria se puede extraer aproximadamente el 10% de las reservas totales del campo. Se puede obtener otro 30% de la recuperación secundaria y hasta otro 30% mientras de la recuperación terciaria. Esta última, sin embargo, normalmente no se lleva a cabo ya que implica una inversión considerable y una alta incertidumbre (COT, 2007).

El descubrimiento de nuevas fuentes de hidrocarburos durante las últimas décadas no ha sido suficiente para remplazar las reservas actuales (Alvarado y Manrique, 2010). Según Alvarado y Manrique (2010) la mayor parte de la producción actual de petróleo, o al menos el 50%, proviene de yacimientos maduros; debido a la disminución de nuevos descubrimientos importantes sobre el terreno, el lugar más probable para encontrar más petróleo son los lugares en los que ya se ha encontrado antes. Por lo tanto, debe aplicarse nuevas técnicas para extraer la mayor cantidad posible de aceite. Estas técnicas se conocen como Recuperación Mejorada de Petróleo (EOR: Enhanced Oil Recovery).

En 2010 la Secretaría de Energía y Conacyt lanzaron la convocatoria de un proyecto para investigar el uso de técnicas de inteligencia artificial para apoyar una recuperación óptima de petróleo en campos maduros. La idea básica era aprovechar las grandes cantidades de datos que Pemex Exploración y Producción ha obtenido en sus años de operación.

Los autores de este artículo, en colaboración con colegas del INAOE, desarrollaron el modelo de selección de pozos (FSCS-H, 2013). Este modelo permite la toma de decisión de acciones de intervención de pozos que optimicen la producción de petróleo. Para ello, separaron el problema en dos fases. Primero, la generación de mapas de interconexión entre pozos, y segundo el diseño de un sistema de toma de decisiones basado en ese mapa de interconexión. Para la primera fase utilizaron redes bayesianas y para el segundo utilizaron los diagramas de influencia. Se desarrollaron ambas fases del proyecto y se probaron con los mismos datos históricos de Pemex. Sin embargo, la validación en campo implica la realización de otro proyecto, lo cual no ha ocurrido hasta la fecha. El proyecto se realizó y entregó a Pemex quienes expresaron su interés en llevar esta propuesta a un siguiente paso de trabajo en campo.

El propósito de este artículo es describir el desarrollo del proyecto para Pemex de manera que se puedan discutir las similitudes y diferencias que existen entre los campos petroleros y los campos geotérmicos. Con base en esas diferencias se pueden discutir las adecuaciones necesarias para pozos geotérmicos y se puede proponer un proyecto de investigación para el diseño de un modelo de selección de pozos geotérmicos.

Este artículo se organiza de la forma siguiente. La siguiente sección describe brevemente las bases de los métodos gráficos probabilísticos utilizados en este proyecto: las redes bayesianas y los diagramas de influencia. La sección 3 describe la construcción de mapas de interconexión de pozos utilizando algoritmos de aprendizaje automático de redes Bayesianas. La sección 4 utiliza los mapas definidos y los convierte en diagramas de influencia para la selección óptima de acciones o decisiones en la intervención de pozos. La sección 5 discute los resultados obtenidos en el proyecto para Pemex y apunta las directrices para la aplicación de estas técnicas en pozos geotérmicos. Finalmente, la sección 6 concluye el artículo.

2. Modelos gráficos probabilistas

En esta sección se introducen las bases de las redes bayesianas y los diagramas de influencia utilizados en el proyecto.

Las redes bayesianas son grafos acíclicos dirigidos $G=(N,V)$ donde N es un conjunto de nodos y V un conjunto de arcos o vértices (Judea, 1988). El grafo G representa la relación probabilista entre las variables de una aplicación. Los nodos representan las variables y los arcos representan la relación probabilista entre ellos. Esa relación sigue a la fórmula del teorema de Bayes como se puede ver en la Figura 1.

El nodo destino del arco (evidencia) es probabilísticamente dependiente del nodo origen (hipótesis). Su relación se describe en la matriz de probabilidad condicional del nodo hijo dado los valores del nodo padre. Entonces, para calcular la probabilidad de la hipótesis, por ejemplo fiebre dado infección $P(H|E)$, se utiliza la probabilidad de fiebre knowing que existe infección $P(E|H)$.

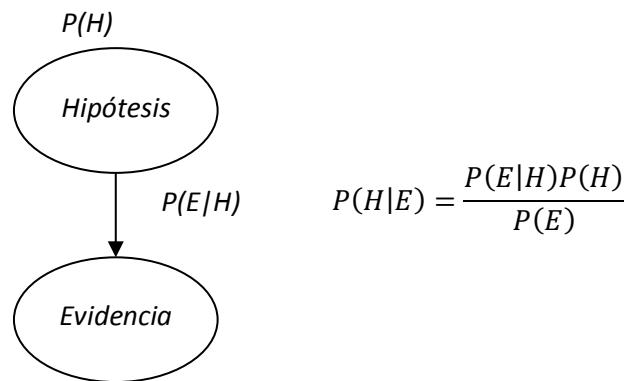


Figura 1. Ejemplo de red Bayesiana elemental. Se puede apreciar la correspondencia entre el grafo y el Teorema de Bayes.

Por lo tanto, para codificar el conocimiento que se tiene de algún proceso se requiere que se forme el modelo con los siguientes ingredientes:

- a) La estructura de la red donde se codifiquen las dependencias y las independencias entre variables (conocimiento cualitativo), y
- b) Los parámetros, formados por las matrices de probabilidad condicional de los nodos hijos, dados sus padres y los vectores de probabilidad *a priori* de los nodos raíz (conocimiento cuantitativo).

La Figura 2 muestra un ejemplo de red Bayesiana formada por 5 variables. En ella se muestra una relación probabilista de la variable *t* dado *m*. Las redes bayesianas muestran también relaciones de independencia. Por ejemplo, la ausencia de arcos implica una independencia entre la variable *g* y la variable *p* (Russel and Norvig, 2002).

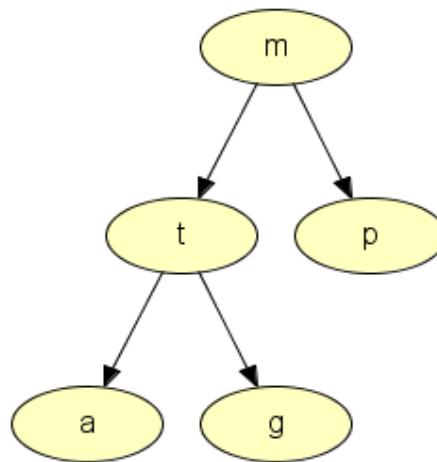


Figura 2. Ejemplo de red Bayesiana de cinco variables

Una restricción importante en las redes bayesianas es que fueron creadas para utilizarse con variables discretas, es decir, aquellas que pueden tener un número finito de valores diferentes. Aunque hay algunos esfuerzos para utilizar redes bayesianas con señales continuas, en este proyecto se utilizó la

discretización de los valores continuos de producción o inyección. Por discretización se entiende la traducción de los valores continuos en un número finito de intervalos de valores.

Hay tres formas de definir la estructura de una red bayesiana:

- a) Definición de las dependencias e independencias por parte de un experto humano en el tema.
- b) Con base en datos históricos de las variables participantes, utilizando alguno de los múltiples algoritmos de aprendizaje automático (Neapolitan, 2004). Estos algoritmos pertenecen a las técnicas de aprendizaje de máquina (*machine learning*) o de minería de datos (*data mining*).
- c) Una combinación de los anteriores. Muchos algoritmos permiten la colaboración de expertos en la formación de los modelos.

Cabe señalar los intensos esfuerzos de la comunidad internacional de inteligencia artificial para desarrollar algoritmos de aprendizaje más robustos y más eficientes, tomando en cuenta la gran cantidad de datos disponibles en la mayoría de las aplicaciones.

La utilización de los modelos en forma de redes bayesianas consiste en la adquisición de los valores de algunas variables. Estas se introducen al modelo y se realiza entonces el cálculo de las probabilidades *a posteriori* de las variables consideradas como hipótesis. Este proceso se conoce como inferencia probabilista (FSCS-H, 2013). Consiste en propagar la información conocida y con los parámetros definidos en el modelo se calcula el vector de probabilidad de ocurrencia de las variables no definidas. Por ejemplo, en una red bayesiana de diagnóstico médico se introducen los síntomas detectados en el paciente (temperatura corporal, dolores, análisis) y se calcula la probabilidad de tener alguna de las enfermedades modeladas en la red.

La otra técnica de la presente propuesta son los diagramas de influencia (Judea, 1988; Howard and Matheson, 1984). Los diagramas de influencia son una extensión de las redes bayesianas y se utilizan para el soporte de expertos en la toma de decisiones que involucren incertidumbre. Se forma de una red bayesiana adicionada con los siguientes dos tipos de nodos:

1. Nodo de decisión. Los valores que puede tomar este nodo son las decisiones que el experto puede tomar. Los arcos que ingresan a este nodo representan la información que el experto debe conocer al tomar la decisión. Se representan con un rectángulo en los modelos.
2. Nodo de utilidad. Calcula el valor de utilidad que se logra al tomar una decisión. Los arcos que ingresan a este nodo representan la información necesaria para calcular una utilidad. Debe ser un valor numérico. Se representan con un rombo en los modelos.

La inferencia en estos diagramas consiste también en asignar valores a los nodos probabilistas conocidos, asignar el valor al nodo de decisión y calcular la utilidad de esa decisión. Con esto se puede lograr la selección de la decisión óptima, dada la información actual en un proceso o aplicación (Judea, 1988; Russel and Norvig, 2002). La Figura 6 muestra más adelante un ejemplo de diagrama de influencia.

3. Construcción de mapas de conectividad

En esta sección se presenta el método propuesto para construir mapas de interconexión entre pozos, utilizando el mecanismo de las redes bayesianas.

La idea central de esta propuesta se basa en la suposición de que los datos históricos de inyección y producción de pozos pueden identificar la interconexión que puede haber entre ellos. Es decir, analizando la historia de cuándo se han intervenido los pozos inyectores y revisando los cambios en la producción de otros pozos, se puede inferir que hay cierta probabilidad de que exista interconexión entre ellos. Contando con suficiente información y con los algoritmos mencionados de aprendizaje de modelos, se puede lograr un modelo equivalente a la interconexión de pozos.

A manera de ejemplo, supóngase un trozo de base de datos como la mostrada en la Figura 3.

Q_2B	Iny_4	Iny_521	Iny_523	Iny_109	Iny_600	Iny_654	Iny_121	Iny_466	Iny_107	Iny_120	Iny_517	Iny_800
96413.12	NaN	NaN	NaN	445.01	NaN							
99168.769	NaN	NaN	NaN	577.87	NaN							
95984.142	NaN	NaN	NaN	479.11	NaN							
99365.646	NaN	NaN	NaN	618.15	NaN							
99359.985	NaN	NaN	NaN	447.56	NaN							
92678.747	NaN	NaN	NaN	402.62	NaN							
93517.833	NaN	NaN	NaN	436.86	NaN							
90515.616	NaN	NaN	NaN	422.01	NaN							
62841.503	NaN	NaN	NaN	418.55	NaN							
NaN	NaN	NaN	NaN	108.84	NaN							
NaN	423.98	806.6	1046.61	NaN	854.14	NaN	NaN	95.44	131.47	NaN	NaN	211.42
NaN	580.83	580.83	NaN	NaN	896.31	NaN	NaN	124.05	133.24	NaN	NaN	508.23
NaN	659.98	659.98	NaN	NaN	938.75	NaN	NaN	129.56	9.61	NaN	NaN	525.73
NaN	635.96	635.96	NaN	NaN	1007.79	NaN	NaN	113.78	0	NaN	NaN	502.53
NaN	650.4	650.98	NaN	NaN	1055.27	NaN	NaN	106.82	0	NaN	NaN	513.53
NaN	767.9	1267.26	NaN	NaN	1072.88	8.58	1.67	75.15	0	NaN	NaN	561.35
NaN	1082.96	1082.96	NaN	NaN	577.65	263.04	51.04	78.51	0	NaN	NaN	357.8
NaN	485.53	1209.96	NaN	NaN	681.1	327.36	63.53	97.72	0	68.7	21.24	386.08
NaN	0	1145.18	NaN	NaN	629.33	138.98	26.96	43.26	0	266.33	254.13	832.19
NaN	0	1249.95	NaN	NaN	590.39	413.8	80.24	123.49	97.53	158.57	32.54	339.3
NaN	0	1128.16	NaN	NaN	355.17	421.42	81.78	125.79	NaN	306.77	63.26	588.63
NaN	0	1095.12	NaN	NaN	262.21	284.71	55.24	84.98	NaN	239.18	66.69	441.61
NaN	603.16	1246.47	NaN	NaN	346.67	59.98	11.65	691.8	NaN	42.57	43.91	986.15
NaN	1136.9	1136.9	NaN	NaN	321.64	NaN	NaN	577.12	NaN	NaN	NaN	924.2
NaN	1237.5	1237.5	NaN	NaN	252.99	NaN	NaN	487.3	NaN	NaN	NaN	671.02
NaN	1187.64	1187.64	NaN	NaN	326.02	NaN	NaN	685.4	NaN	NaN	NaN	898.264
NaN	1231.81	1231.81	NaN	NaN	249.06	NaN	NaN	454.99	NaN	NaN	NaN	588.53
NaN	1224.92	1224.92	NaN	NaN	334.14	NaN	NaN	685.21	NaN	NaN	NaN	917.688

Figura 3. Segmento de la base de datos del archivo con producción del pozo Q_2B y la intervención en pozos de inyección.

La Figura 3 muestra la selección de la base de datos de un pozo productor (Q_2B) con todos los pozos inyectores. Las celdas marcadas con NaN (Not a Number) indican que no existe un número válido en la captura de ese parámetro. Cabe señalar también que cada renglón de la tabla representa el reporte de producción mensual.

Al aplicar el algoritmo de aprendizaje PC (Spirtes et al., 2000) se aprende la relación entre un pozo productor y n pozos inyectores. Repitiendo este procedimiento para los m pozos productores, se genera un arreglo mxn como el mostrado en la Figura 4. Nótese que de los cerca de 20 pozos involucrados en el aprendizaje, sólo se encontró posible interconexión entre los pozos Inyectores Iny_800 e Iny_600 con el pozo productor Q_2C y entre los inyectores Iny_600 e Iny_4 con el productor Q_2B. Los demás se consideran aislados con este método.

La estructura de la red bayesiana representa la detección realizada con este método del mapa de interconexión entre los pozos del campo considerado. Nótese que se restringe el método para la interconexión únicamente entre pozos productores e inyectores, pero no entre los del mismo tipo.

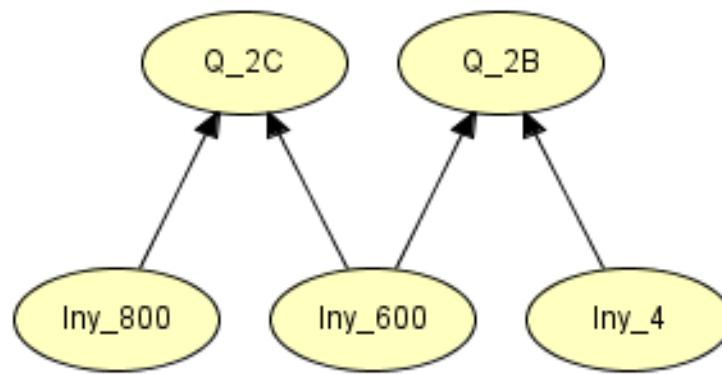


Figura 4. Ejemplo de red bayesiana representando el mapa de interconexión entre pozos inyectores y productores.

Una vez logrado el mapa de interconexión, se transforma la red Bayesiana en diagrama de influencia para el soporte a la toma de decisiones. La siguiente sección explica este procedimiento.

4. Diagramas de influencia para la decisión óptima de intervención de pozos

Como se mencionó anteriormente, los diagramas de influencia son un mecanismo de soporte a la toma de decisiones en presencia de incertidumbre. Permiten calcular la utilidad de cada decisión posible en presencia de incertidumbre y con ello se puede obtener la decisión óptima.

La metodología para convertir una red bayesiana en un diagrama de influencia consiste en los siguientes pasos.

Paso 1: Convertir los nodos probabilistas de pozos inyectores en nodos de decisión. Esto es porque las decisiones que se tomarán utilizando esta metodología serán la cantidad de inyección a ciertos pozos. Partiendo del mapa de la Figura 4, se genera un diagrama como el mostrado en la Figura 5.

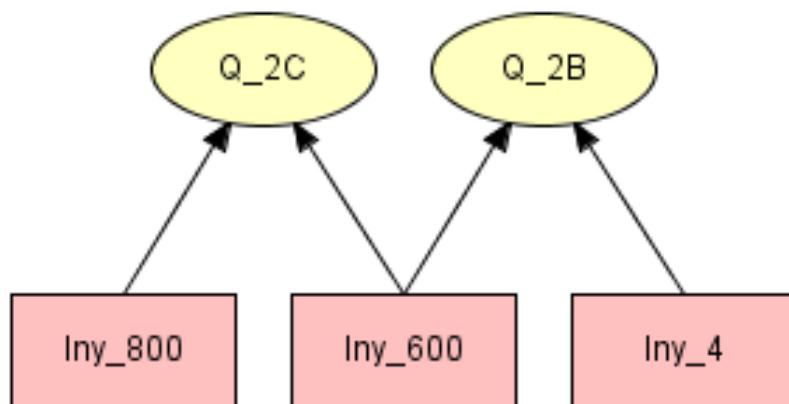


Figura 5. Conversión de los nodos de pozos inyectores en nodos de decisión. Los valores de estos nodos permanecen.

Paso 2: Aumentar nodos de utilidad. Se requiere un nodo de utilidad por cada nodo de pozo productor. Insertar un arco entre el nodo de pozo productor y el nodo de utilidad, así como otro arco entre el nodo de decisión y el nodo de utilidad a fin de completar lo mencionado anteriormente. Los arcos entrando a los nodos de utilidad representan la información necesaria para calcular la utilidad. En este caso, cuánto se inyectó al pozo inyector y cuánto se produjo en el pozo productor.

Paso 3: Configurar los nodos de utilidad. Definir una ecuación que contenga la decisión tomada y la producción lograda. La Figura 6 muestra el ejemplo seguido en este artículo.

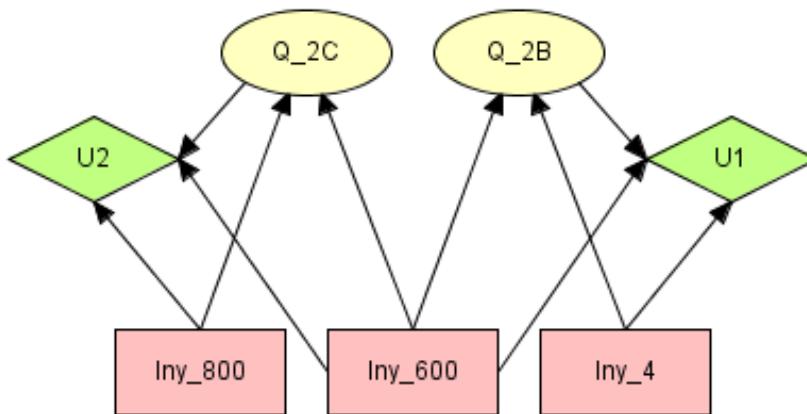


Figura 6. Diagrama de influencia resultante.

Para la configuración de los nodos de utilidad en el proyecto para Pemex se propusieron las siguientes dos métricas de la ganancia:

- Ganancia relativa. Para cada pozo inyector i , calcular la ganancia de cada pozo productor q con la siguiente ecuación:

$$G_{qi} = \frac{Q \times (\text{precio petróleo})}{I \times (\text{precio gas inyectado})}$$

- Ganancia absoluta. Para cada pozo inyector i , calcular la ganancia de cada pozo productor q con la siguiente ecuación:

$$G_{qi} = Q \times (\text{precio petróleo}) - I \times (\text{precio gas inyectado})$$

Estas ecuaciones representan la relación entre la ganancia en dólares de la producción, con el costo en dólares de la inyección de algún gas (gas natural/nitrógeno). El precio del petróleo es en dólares por barril, mientras que el precio del gas inyectado es en dólares por metro cúbico.

Para calcular la ganancia total lograda por un pozo inyector j , se calcula:

$$U_j = \max_{li} \left[P_i \left(\sum_q G_{qi} P(Q_q) \right) \right]$$

Donde q es el intervalo del nodo de producción, i es el intervalo del nodo de inyección, $P(Qq)$ es la probabilidad asociada al estado q del productor Q .

Finalmente, la utilidad total será:

$$U_{total} = \sum_j U_j$$

Donde j son los nodos de utilidad correspondientes a cada nodo de decisión de inyección.

La Figura 7 muestra un ejemplo de los diagramas de influencia logrados en el proyecto de Pemex.

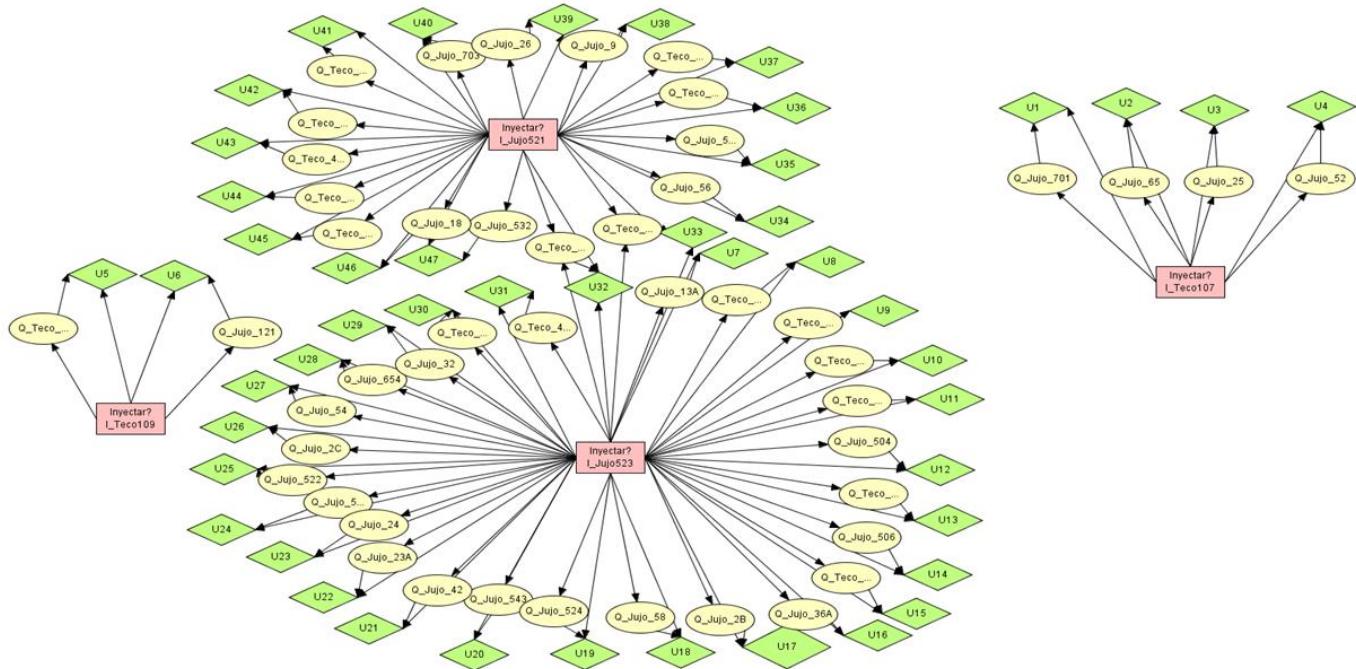


Figura 7 Ejemplo de diagrama de influencia construido para un campo petrolero.

Nótese que en el ejemplo de Pemex se encontraron únicamente 4 pozos inyectores con influencia en los demás pozos productores. De hecho, se identificaron conjuntos aislados de pozos inyectores/productores como se puede apreciar en la Figura 7.

5. Discusión

La propuesta presentada en este artículo fue desarrollada utilizando datos históricos de intervenciones y producciones de pozos en un campo productor de petróleo. Los experimentos realizados se refieren a corridas del sistema donde se identifica la decisión óptima que el personal de Pemex debería ejecutar para maximizar la producción.

Sin embargo, no se llevó a cabo la realización de estos experimentos en campo por restricciones propias de la empresa. Serían necesarios datos más recientes de los pozos de un campo, del historial de las intervenciones, del estado de los pozos (cerrados por ejemplo) para poder sugerir las acciones óptimas. Después de eso, validar los resultados con tiempos de respuesta de meses.

Se espera poder tener la oportunidad de probar estas técnicas, ya sea en un campo petrolero o un campo geotérmico.

Por lo pronto, se reconocen las siguientes actividades para la adopción de esta tecnología al ambiente geotérmico:

- Analizar el caso de pozos geotérmicos para identificar las similitudes con el caso petrolero. En caso de requerir adecuaciones, hacer una propuesta para el caso geotérmico.
- Adquirir datos históricos de algún campo geotérmico para ser capaces de repetir toda la metodología para el caso.
- Identificar si existe alguna forma de validar los mapas de interconexión en el caso geotérmico.
- Cambiar las ecuaciones de las métricas de utilidad al caso geotérmico. Probablemente se utilicen kilowatts generados o el precio de venta del kW generado.
- Revisar la correspondencia entre inyección y diferencia de producción al momento.
- Medir el retraso típico en cada campo.

Los dos últimos puntos se refieren a la suposición de relacionar los datos sobre intervención del pozo con la información de producción en el mismo momento. Suena razonable considerar que hay un tiempo de retraso entre la intervención en un pozo y los efectos en otros. Se requiere medir ese retraso en el caso geotérmico. De la misma manera, la evaluación de la utilidad considera actualmente la producción al momento de la inyección. Se requiere entonces un ajuste necesario en la ganancia de producción, fruto de la inyección después del retraso medido.

6. Conclusiones

Este artículo presenta los resultados de un proyecto realizado para campos petroleros sobre el uso de técnicas de inteligencia artificial para el tratamiento de pozos maduros. Las técnicas utilizadas son modelos gráficos probabilistas, específicamente redes bayesianas y diagramas de influencia.

El modelo de selección de pozos partió de grandes cantidades de datos históricos de producción e intervención de pozos en campos maduros. Es una propuesta novedosa, relativamente fácil de implantar y que se considera que puede aportar dividendos importantes en la producción de petróleo.

Se considera posible aplicar las mismas técnicas en pozos de campos geotérmicos, por lo que se analizarán las opciones para validarlas.

Referencias

- Alvarado, V., and Manrique, E., 2010. Enhanced Oil Recovery: An update review. *Energies*, No. 3.
- COT (China Oilfield Technology), 2007. Three phases of Oil Recovery. [Online]. <http://www.chinaoilfieldtech.com/oilrecovery.html>.
- FSCS-H (Fondo Sectorial Conacyt-SENER Hidrocarburos), 2013. Modelo de decisiones para la selección de pozos inyectores en procesos de recuperación secundaria y mejorada aplicando mecanismos de aprendizaje automático. Reporte Técnico Final, Proyecto 146515. Inédito.
- Howard, R.A., and Matheson, J.E., 1984. Influence Diagrams. In: Howard, R.A., and Matheson, J.E. (eds.), *Readings on the Principles and Applications of Decision Analysis*, Strategic Decision Group, pp. 721-762.

Judea, P., 1988. *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann, Palo Alto, California, USA.

Neapolitan, R.R., 2003. Learning Bayesian Networks. Prentice Hall, New Jersey, USA.

Russell, S., and Norvig, P., 2002. *Artificial Intelligence, a modern approach*. Prentice Hall, Third edition.

Spirites, P., Glymour, C., and Sheines, R., 2000. Causation, Prediction and Search. MIT Press, Cambridge, Massachusetts, USA.