

# USO DE NEUROSIMULACIÓN EN EL POSICIONAMIENTO DE POZOS DURANTE EL DESARROLLO DE UN CAMPO DE HIDROCARBUROS

Hector Emilio Barrios Molano<sup>1</sup>  
Elkin Rodolfo Santafé Rangel<sup>1</sup>

## RESUMEN

El presente trabajo muestra la implementación de una técnica de neurosimulación para la ubicación de pozos aplicado en el desarrollo de un campo de hidrocarburos heterogéneo y de geometría irregular.

Durante el desarrollo de un campo de hidrocarburos la ubicación de pozos es una de las tareas más importantes, ya que un cambio pequeño en la ubicación puede representar ganancias o pérdidas durante el resto de vida productiva del campo, con este trabajo se plantea una técnica de neurosimulación como alternativa a los métodos convencionales de ubicación de pozos los cuales son costosos y consumen gran cantidad de tiempo. Esta técnica forma un puente entre el *hard-computing* y el *soft-computing*, mezclando eficazmente redes neuronales artificiales (RNA) y simulación numérica de yacimientos, de esta forma usando la simulación numérica de yacimientos sobre unas combinaciones de pozos de entrenamiento se obtienen datos de producción que junto con otros datos son usados para entrenar y ajustar la red, luego se generan escenarios que son evaluados por la RNA entrenada, los mejores resultados se verifican con el simulador numérico de yacimientos, para después predecir la tasa a la cual los pozos producirán y la cantidad cumulativa producida de hidrocarburos.

Para el desarrollo de este trabajo se hace uso de herramientas de código abierto y software libre para incentivar su uso y desarrollo en el campo de la investigación, en la academia y en la industria de los hidrocarburos.

Con este trabajo se muestra un método alternativo de selección de pozos que produzca resultados rápidos y precisos, con los cuales sea fácil tomar la decisión de donde perforar nuevos pozos durante el desarrollo de un campo.

**Palabras claves:** Neurosimulación; Redes Neuronales Artificiales; Simulación Numérica de Yacimientos; Campos Maduros; Desarrollo de Campo de Hidrocarburos; Software Libre; Lenguaje de Programación Python.

## ABSTRACT

This paper shows the implementation of a neurosimulation technique for the well placement applied to the development of a heterogeneous hydrocarbon field with an irregular geometry. During the development of a hydrocarbon field the well placement is a major task, because a small change in location can make gains or losses of money during the remaining productive life of the field; this paper presents a neurosimulation technique as an alternative to conventional methods of well placement which are expensive and consume large amounts of time. This technique is a bridge between *hard-computing* and *soft-computing*; effectively mixes artificial neural networks (ANN) and numerical reservoir simulation, in this way using the numerical reservoir simulation in a combination of training wells, production data are obtained along with other data which are used to train and adjust the network, then a large number of scenarios are generated which are evaluated by the trained ANN, the best results are verified with the numerical reservoir simulation, and then it is possible to predict the rate at which the wells will produce and the cumulative hydrocarbon production.

For the development of this work open source tools and free software was used to encourage their use and development in research, in academia and in hydrocarbon industry.

This work shows an alternative method of selecting wells that produce fast and accurate results, with which it is easy to take the decision about where is the best place to drill new wells during the development of a hydrocarbon field.

**Keywords:** Neurosimulation, artificial neural networks, reservoirs numeric simulation, mature fields, hydrocarbon field development, free software, python.

---

<sup>1</sup> Grupo de Investigación en Tecnologías Alternativas para Hidrocarburos (GITAH), Universidad Industrial de Santander (UIS). Bucaramanga. Colombia. E-mail: hebm12@gmail.com, elkinsan@uis.edu.co

## INTRODUCCIÓN

La ubicación estratégica de nuevos pozos de desarrollo en un campo en producción es una tarea que puede consumir mucho tiempo y costos y puede ser realizada con un alto grado de aleatoriedad.

Un pequeño cambio en la posición puede representar ganancias o pérdidas durante el resto de vida productiva del campo. Los resultados de este estudio demuestran la efectividad de una metodología que combina redes neuronales artificiales y simulación numérica de yacimientos frente a diferentes pruebas. Las pruebas son llevadas a cabo en un modelo en dos dimensiones de un yacimiento de gas con complejidad creciente, en la medida que la complejidad aumenta, la arquitectura de la red neuronal artificial es ajustada para manejar heterogeneidad y fronteras irregulares.

## METODOLOGÍA

La metodología básicamente requiere una serie de pasos mostrados en la Figura 1. Todo el proceso fue automatizado usando una serie de archivos de ordenes scripts escritos en el lenguaje de programación Python que a su vez transfieren datos para comunicar el simulador numérico de yacimientos con el simulador de redes neuronales artificiales.

**Paso 1: Discretización.** Esta etapa consiste en dividir el dominio físico de interés (en este caso el yacimiento) para iniciar el proceso de ubicación de pozos.

**Paso 2: Selección de pozos de entrenamiento.** Una vez los pozos existentes son ubicados, un grupo de pozos de entrenamiento es generado en diferentes posiciones del yacimiento. Estos pozos de entrenamiento deben ser ubicados en las fronteras, en espacios entre los pozos existentes y donde se presenten fuertes cambios en el modelo petrofísico y en el modelo PVT del fluido; estas ubicaciones intentan describir el yacimiento tan bien como sea posible, teniendo en cuenta que a un mayor número de pozos de entrenamiento el tiempo de simulación aumenta, además, con un número muy pequeño de pozos de entrenamiento no se obtendrán datos suficientes para una buena descripción del yacimiento, llevando a un mal entrenamiento de la red neuronal.

**Paso 3: Simulación.** Aquí se simula, todas las posibles combinaciones entre pozos de entrenamiento usando un simulador numérico de yacimientos; los resultados de la simulación y los datos de producción, son procesados para luego entrenar la red neuronal artificial.

**Paso 4: Entrenamiento de la Red Neuronal Artificial.**

Con los datos obtenidos de las simulaciones la RNA es entrenada, esto se hace usando periodos cortos de entrenamiento para promover la estabilización de los pesos sinápticos de la red y de esta manera obtener tasas de error aceptables. La arquitectura de la red neuronal puede ser modificada en términos del número de neuronas en la capa de entrada y en la capa oculta, dependiendo del caso a analizar.

**Paso 5: Generación de escenarios.** Usando las ubicaciones posibles para los pozos nuevos, miles de combinaciones aleatorias son creadas; usando un criterio de selección se analizan las configuraciones posibles que pueden servir como potenciales para mejorar la producción del campo.

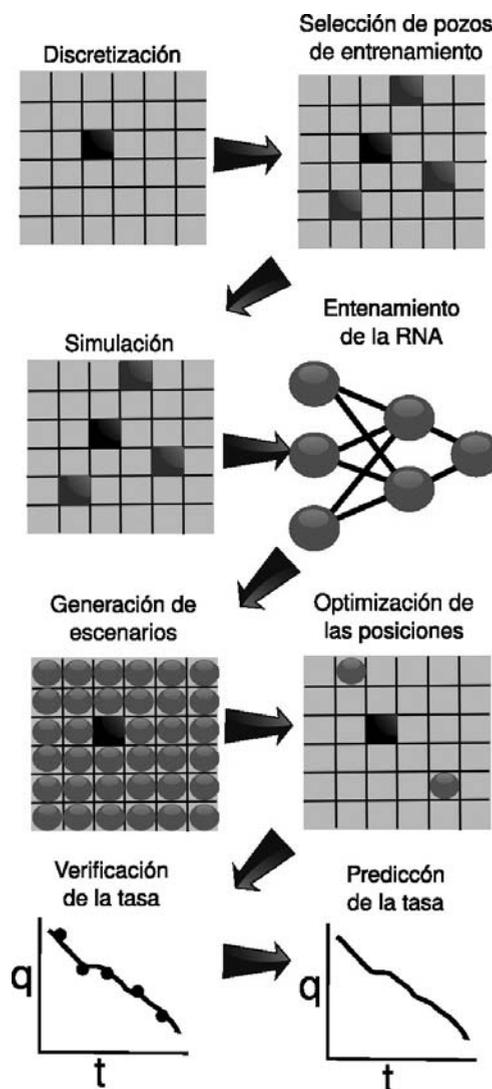


Figura 1: El proceso de Neurosimulación

**Paso 6: Optimización de las posiciones.** Una vez la red es entrenada, el grupo de combinaciones resultado del paso anterior es analizado por la RNA y se predice una tasa de producción. La combinación que mejor representa el mejor comportamiento en la producción, es la combinación en donde se deben ubicar los pozos nuevos.

**Paso 7: Verificación las tasas.** Una vez la red ha sugerido un patrón de producción, éste es evaluado en un modelo de simulación con el ánimo de verificar los resultados de la red asociados con esta variable.

**Paso 8: Predicción de la tasa.** Este paso está muy unido al paso anterior, siendo una delgada línea la que los separa. La red servirá como un modelo predictivo de la producción del campo bajo la nueva configuración de pozos.

- Todos los pozos dentro de los límites del yacimiento.
- Un pozo ubicado a lo largo de los límites y dos pozos dentro de los límites.

**Tabla 1:** Propiedades del modelo usado en la prueba No.1

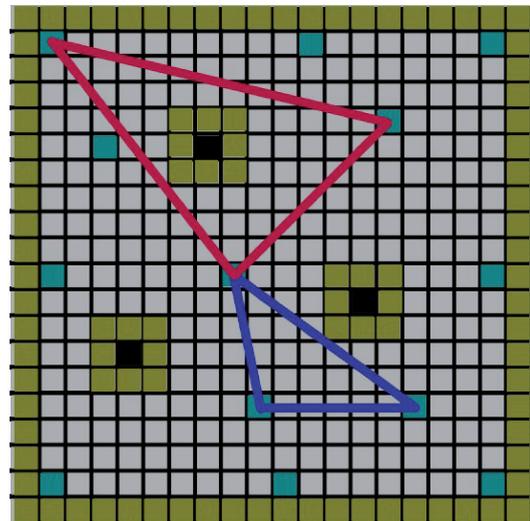
|                                |           |
|--------------------------------|-----------|
| Presión inicial del yacimiento | 6200 psia |
| Temperatura del yacimiento     | 144 °F    |
| Permeabilidad del yacimiento   | 25md      |
| Porosidad                      | 25%       |
| $\Delta x = \Delta y$          | 75ft      |
| Espesor del yacimiento         | 75ft      |
| Radio del wellbore             | 0.25ft    |

## PRUEBAS, RESULTADOS Y ANÁLISIS

**Prueba No.1: Yacimiento homogéneo con límites regulares.** El modelo es un campo de gas donde las propiedades y dimensiones son dadas en la Tabla No. 1. Hay 3 pozos produciendo por 500 días a una presión de 1100 psia en las posiciones mostradas con cuadros negros en la Figura 2, se intenta ubicar tres nuevos pozos para producir por 500 días adicionales. Aplicando la metodología descrita, los pozos de entrenamiento fueron seleccionados bajo el siguiente criterio:

- Proximidad a los límites del yacimiento.
- Proximidad a pozos existentes.
- Espacio inter-pozos.
- Áreas donde existan fuertes gradientes de propiedades.

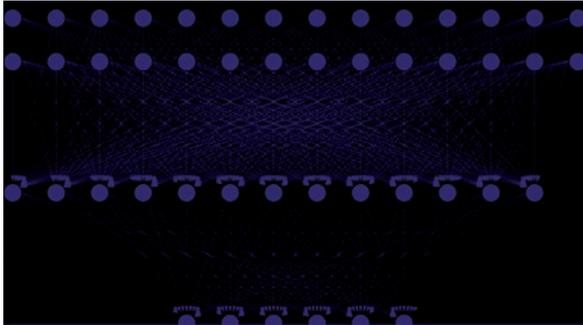
El número total de pozos de entrenamiento depende del caso estudiado. A mayor número de pozos de entrenamiento, mayor es la precisión de la red, pero también se incrementa la carga computacional requerida en la simulación para el entrenamiento. En este caso, 13 pozos fueron usados para entrenamiento, los cuales se indican con cuadros verdes en la Figura 2. Después de que los pozos de entrenamiento fueron seleccionados, todas las posibles combinaciones de tres pozos son producidas. Luego, todas estas combinaciones son pasadas por un filtro; éste consiste en que sólo se permite un pozo nuevo a lo largo de las fronteras; así, el grupo de combinaciones resultante es usado para entrenar la RNA, las combinaciones de pozos permitidas son (como se muestra en la Figura 2):



**Figura 2:** Posiciones de los pozos de entrenamiento. Las cajas negras representan la posición de los pozos existentes y las verdes representan los pozos de entrenamiento propuestos para la prueba No. 1, los triángulos representan las combinaciones posibles para los pozos de entrenamiento.

Una vez aplicado el filtro, 90 combinaciones fueron obtenidas favorables para el entrenamiento. Para determinar este factor fue usado, un script en Python que aplica las restricciones descritas. Todas las combinaciones fueron evaluadas en el simulador numérico de yacimientos WinB4D y se calculó la tasa de declive para los seis pozos en el campo después de perforar 3 nuevos pozos. Con los resultados obtenidos por el simulador numérico de yacimientos la red neuronal artificial fue entrenada. La red neuronal artificial usada fue una red backpropagation usando el Stuttgart Neural Network Simulator (SNNS), la Figura 3 muestra la arquitectura de red usada. Todos los datos de entrada fueron normalizados. Para esta prueba los datos de entrada fueron:

- Tiempo.
- Posición X Y de los pozos.
- Expresiones geométricas.
- Enlaces funcionales.



**Figura 3:** Arquitectura de la red neuronal artificial usada en la prueba No. 1. Se puede ver desde arriba hacia abajo la capa de entrada, la capa oculta y la capa de salida.

Las expresiones geométricas proveen a la red dependencia geométrica de la interferencia entre pozos y los efectos de los límites en las tasas de producción; los enlaces funcionales son relaciones entre los datos de entrada y salida de la red, generalmente son funciones polinomiales. En la Tabla No.2 se puede observar la salida. Se obtuvieron buenos resultados (posiciones y flujo) con un número moderado de neuronas de entrada. La red sufre de sobrecarga cuando se incrementa el número de neuronas, lo cual se ha convertido en un indicador para evaluar que tan importante es, debido a que en los modelos posteriores al ser heterogéneos pueden requerir más neuronas de entrada y por lo tanto, exhibir el mismo comportamiento.

**Tabla 2:** Resultados de las configuraciones probadas para la red de la prueba No.1.

| Prueba | Arquitectura | Posiciones | Producción (MMSCF) |       | % Error |
|--------|--------------|------------|--------------------|-------|---------|
|        |              |            | ANN                | SIM   |         |
| ANN 1  | 25:13:6      |            | 41358.75           | 43835 | 5.99    |
| ANN 2  | 27:13:6      |            | 43761.26           | 43693 | 0.16    |
| ANN 3  | 28:13:6      |            | 38319.82           | 43668 | 13.96   |
| ANN 4  | 37:13:6      |            | 37866.47           | 43386 | 12.72   |

**Prueba No. 2: Yacimiento heterogéneo con límites regulares.**

En este modelo los únicos cambios introducidos respecto a la prueba anterior fueron el tamaño de bloques en las direcciones X y Y que aumentaron en 500 ft con el ánimo de incrementar el volumen del yacimiento, y la inclusión de un mapa de permeabilidad para representar la variación de la capacidad conductiva de la roca. Este mapa puede verse en la Figura 4. Los valores de permeabilidad varían entre 30 md y 10 md. Con la configuración inicial de la red no fue posible obtener resultados adecuados aunque la variación en la permeabilidad fue introducida en la capa de entrada, por lo que se recurrió al uso de un mapa que impone un factor de expectativa para cada bloque en la malla. Este factor intenta indicar a la red la expectativa de ubicar un pozo en una posición dada, los valores tomados por este factor dependen del caso estudiado; para este caso, cada valor representa un porcentaje de asociación del bloque a una posición de pozo. Los valores tomados fueron: 0 para no asociación, 0.25 para una asociación pobre, 0.5 para la mitad de asociación y 1 para asociación completa. El mapa de factores de expectativa se puede observar en la Figura 5. El número de pozos de entrenamiento tomados para esta prueba fue el mismo que para la prueba 1 y sus posiciones se muestran en la Figura 6. Una vez la red fue entrenada (la Figura 7 muestra la arquitectura de la red usada), 20000 combinaciones aleatorias fueron tomadas y algunas fueron rechazadas; luego de aplicar los filtros (posiciones iguales, posiciones vecinas, y sólo un pozo a lo largo de las fronteras) fueron 16535 las combinaciones posibles. No fue posible obtener buenos resultados aún, debido a que la red no pudo obtener valores de porcentaje de error menores al 20%, mientras las curvas muestran una tendencia a errores bajos (Figura 8). De esta forma, fue posible detectar que la manera de entrenar la red puede afectar el ajuste, por lo tanto, se escogió entrenar la red en pasos de a 50 ciclos de iteraciones, permitiendo el ajuste de los pesos sinápticos lentamente y obtener valores del porcentaje de error menores de 9% sobre el simulador de yacimientos. El número total de iteraciones en el cual fue posible establecer este porcentaje de error fue 1000; como se muestra en la Figura 9, se obtienen tasas de error mayores si se excede este valor debido a sobreentrenamiento de la red. Los resultados para esta prueba se muestran en la Figura 10.

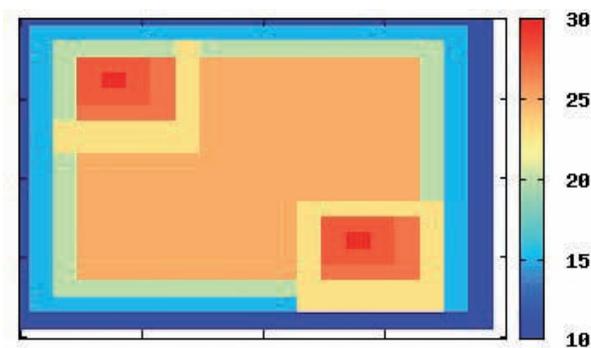


Figura 4: Mapa de permeabilidad asociado con la prueba No.2.

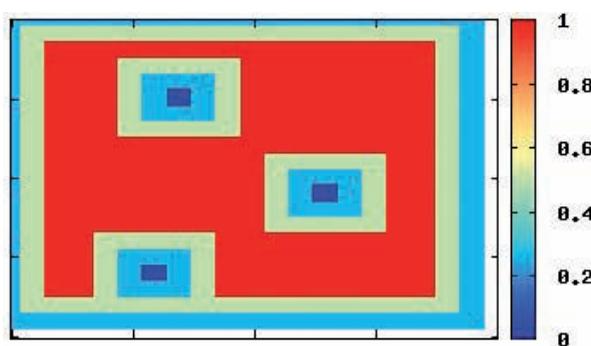


Figura 5: Mapa de factor de expectativa para la prueba No.2.

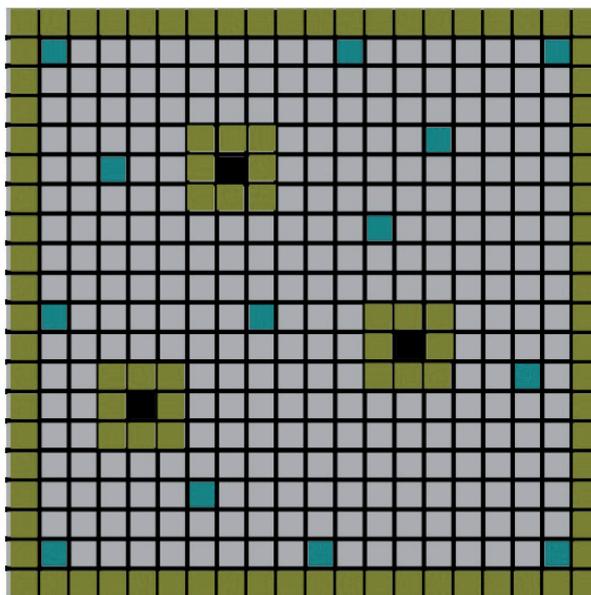


Figura 6: Posiciones de los pozos de entrenamiento. Las cajas negras representan la posición de los pozos existentes y las verdes representan los pozos de entrenamiento propuestos para la prueba No.2.

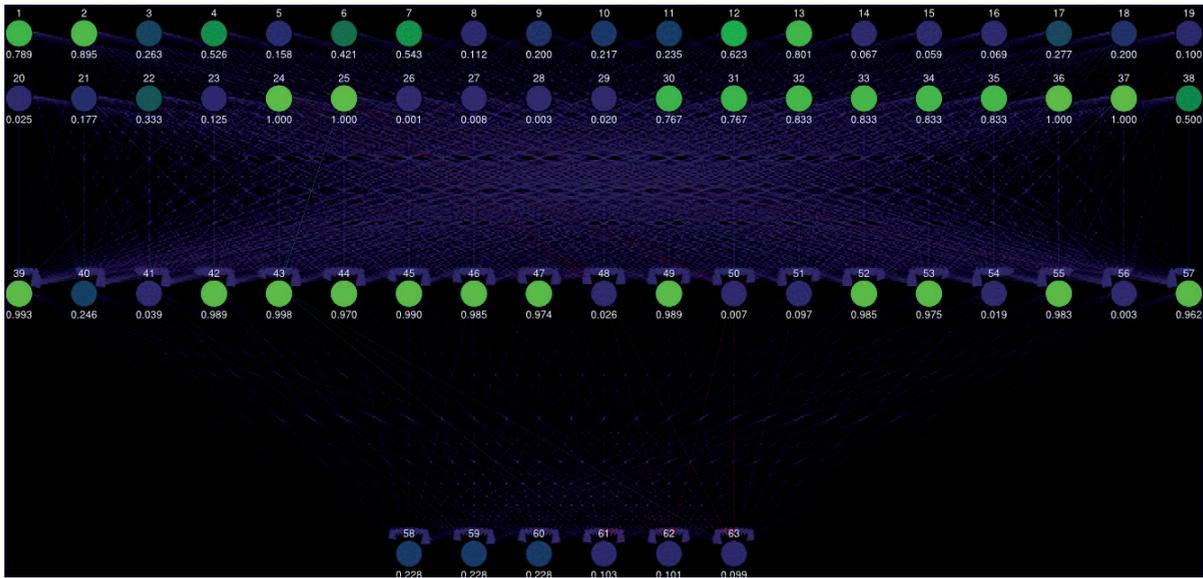


Figura 7: Arquitectura de la red neuronal artificial usado en la prueba No.2 y No.3.

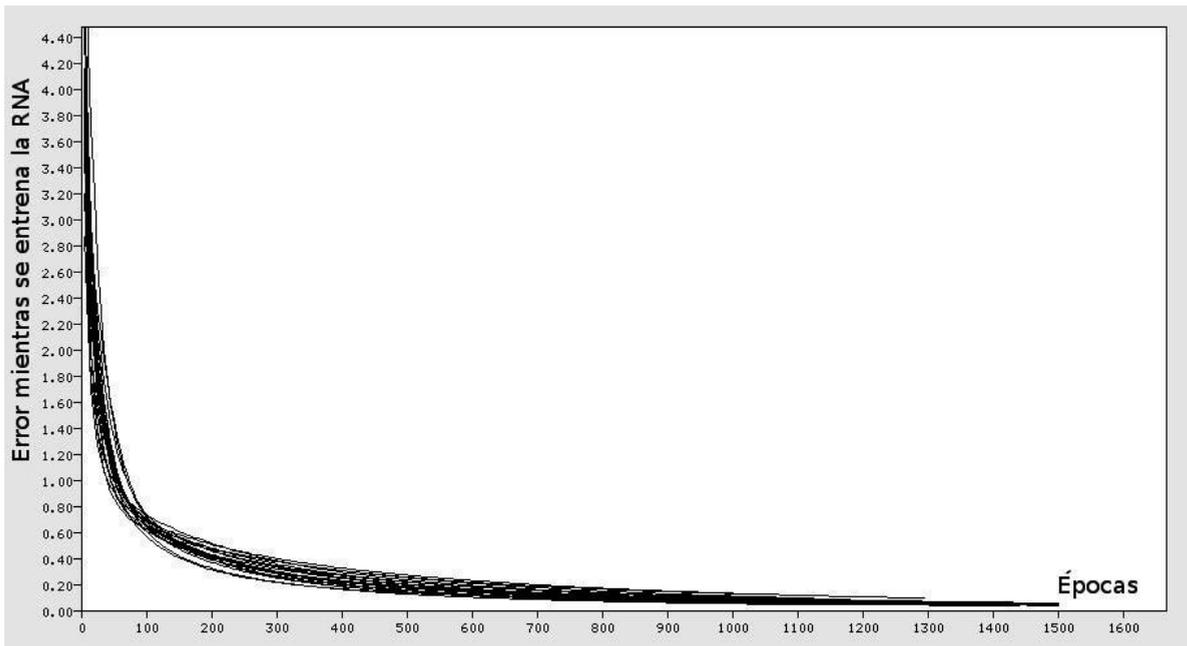


Figura 8: Múltiples pruebas no exitosas en la prueba No.2.

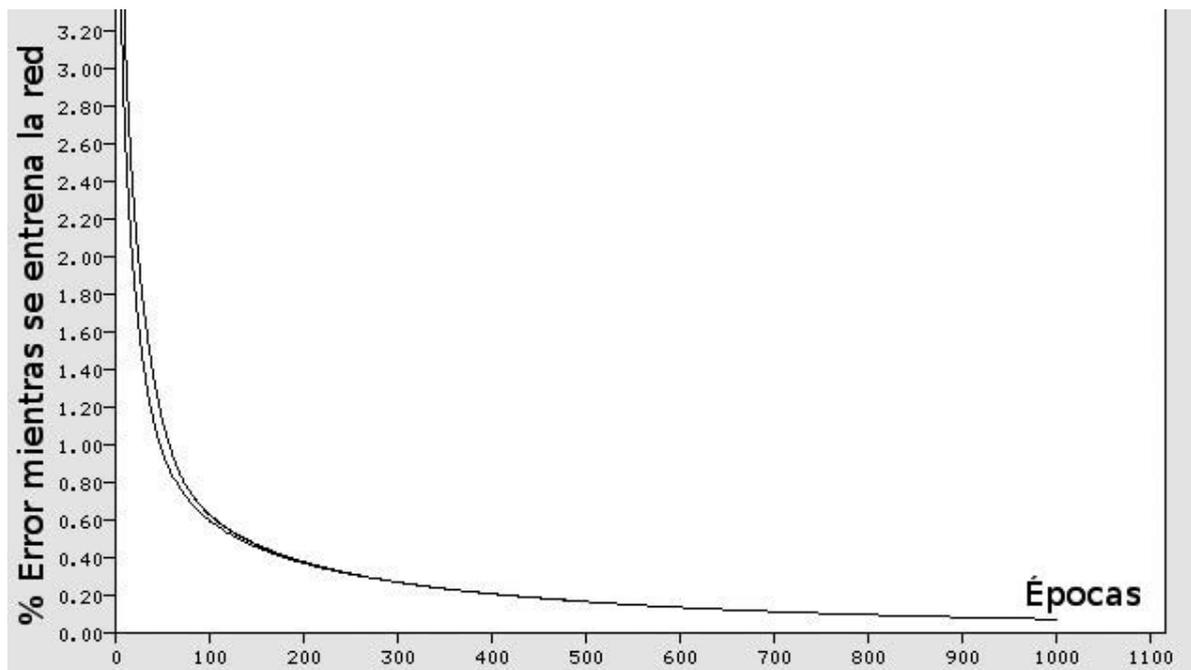


Figura 9: Curva de error asociada con un entrenamiento exitoso para la prueba No.2.

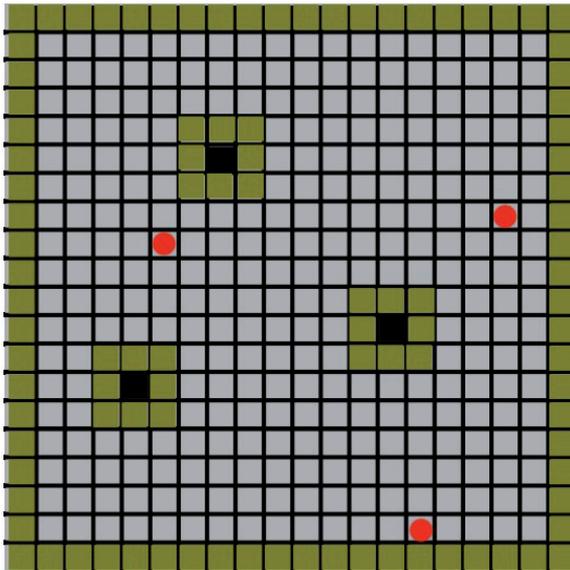
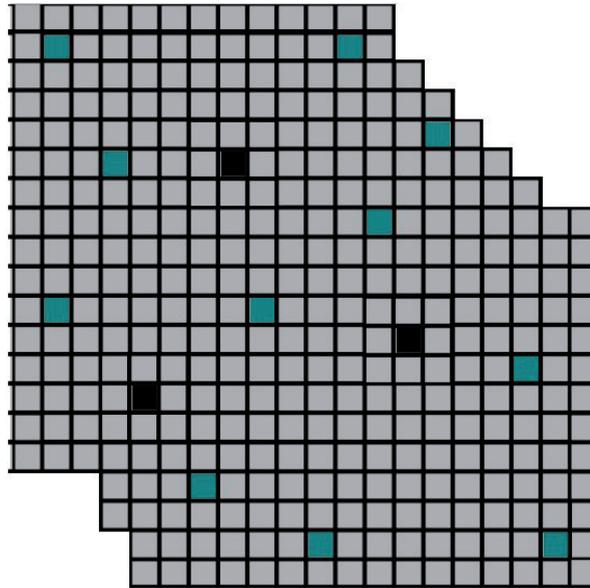
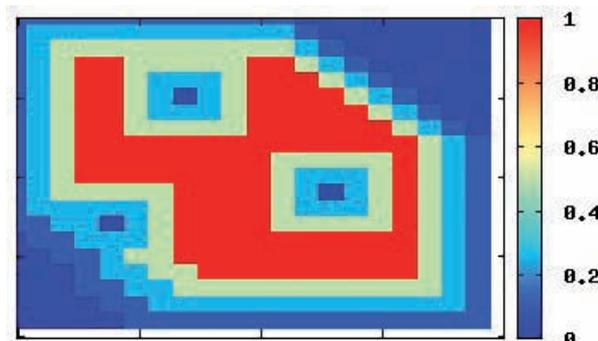


Figura 10: Resultados para la prueba No.2. Círculos rojos: Pozos nuevos.

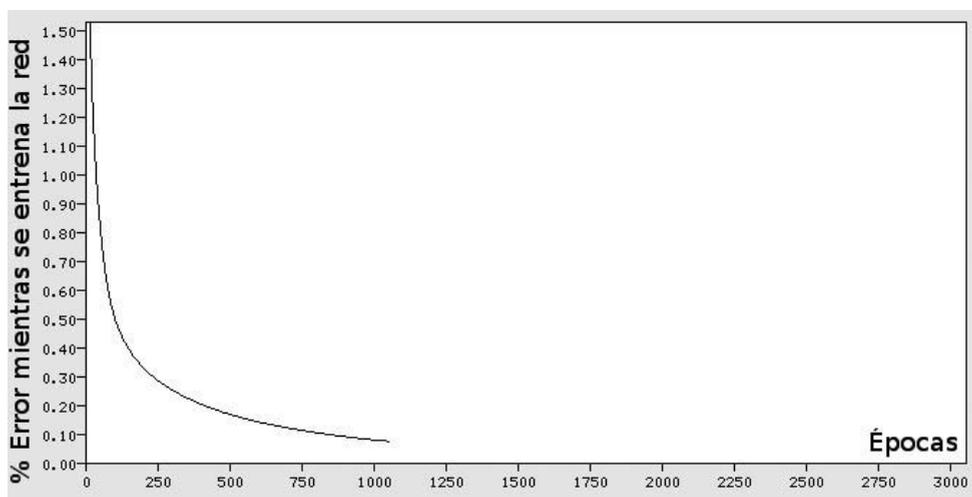
**Prueba No. 3: Yacimiento heterogéneo con límites irregulares.** Este modelo adiciona una geometría irregular, la cual puede ser observada en la Figura 11. En contraste a la prueba No.2, los valores de permeabilidad varían entre 30 md y 0 md, el último valor ha sido usado para representar la barrera de permeabilidad en los límites del yacimiento. El mapa de factor de expectativa es ajustado para que pueda aislar la ubicación de nuevos pozos en los límites del yacimiento; para este caso, los valores del factor de expectativa son: 0 para no asociación, 0.1 para bloques en el límite, 0.25 para una asociación pobre, 0.5 para la mitad de asociación y 1 para asociación completa. El mapa de factor de expectativa se muestra en la Figura 12. El número de pozos de entrenamiento tomados para esta prueba fueron 11 (Figura 11) reteniendo las posiciones que funcionaron en las pruebas anteriores. Una vez entrenada la red, se tomaron 20000 combinaciones aleatorias y luego de aplicar los filtros se obtuvieron 15938 combinaciones posibles. El patrón de comportamiento con respecto a las tasas de error obtenidas fue el mismo que para la prueba No.2, entonces se siguieron los ciclos mecánicos de entrenamiento; esta vez tomó 1050 iteraciones para ajustar los pesos sinápticos (Figura 13). Los resultados tuvieron un porcentaje de error de 9.5% en la mejor posición establecida por la red; la Figura 14 muestra los resultados para la prueba No.3.



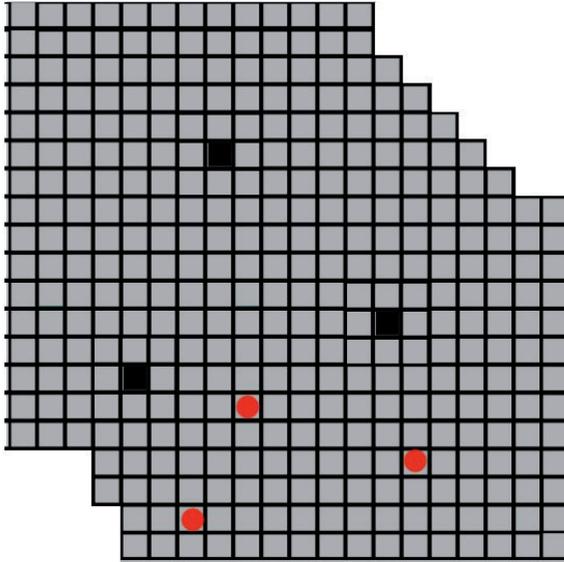
**Figura 11:** Forma general del yacimiento implementado para la prueba No.3 con pozos existentes (cuadros negros) y pozos de entrenamiento (cuadros verdes).



**Figura 12:** Mapa de factor de expectativa implementado para la prueba No.3.

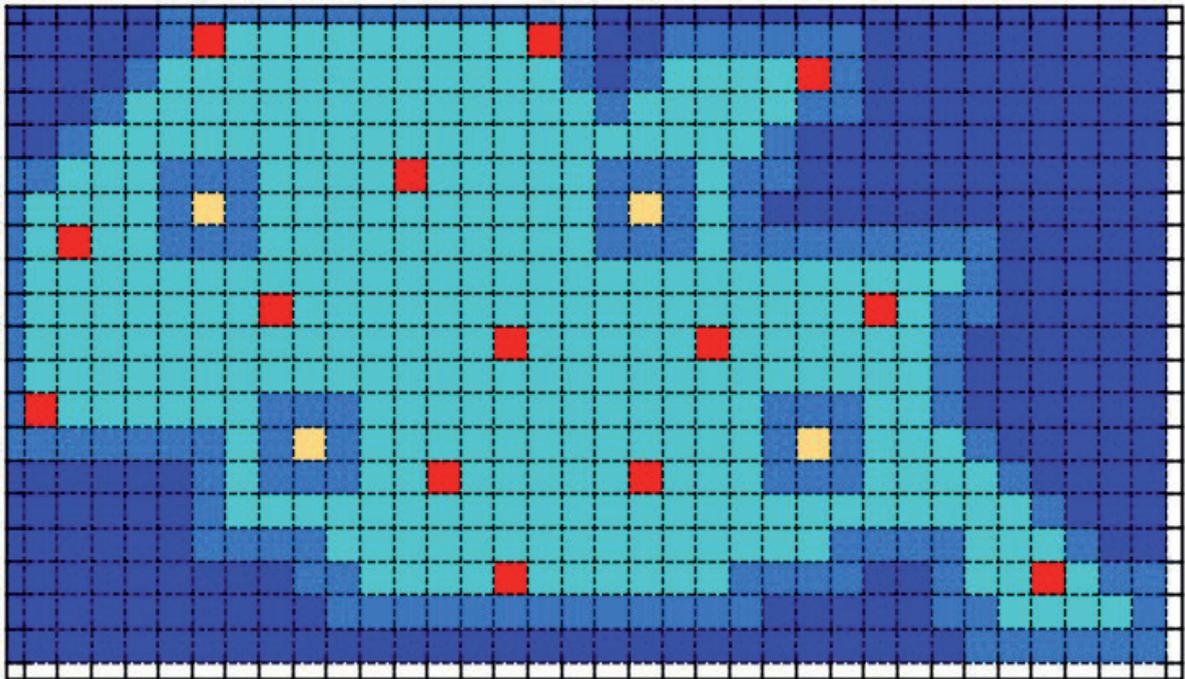


**Figura 13:** Curva de error asociada con entrenamiento exitoso para la prueba No.3.



**Figura 14:** Resultados para la prueba No.3. Círculos rojos: Pozos nuevos.

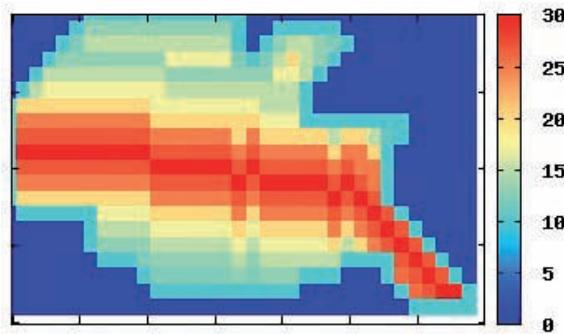
**Prueba No. 4: Yacimiento heterogéneo con límites irregulares y dos etapas de perforación.** Las propiedades del yacimiento se presentan en la Tabla 3, la forma del yacimiento se observa en la Figura 15, con 4 pozos existentes (cajas amarillas) produciendo por 500 días; es necesario ubicar un total de 6 pozos nuevos en el siguiente orden: primero 3 pozos que producirán por 350 días, luego otros 3 pozos nuevos que producirán por otros 350 días. Para la primera etapa de perforación se generó un grupo de 14 pozos de entrenamiento (Figura 15). El mapa de permeabilidad se muestra en la Figura 16 y en la Figura 17 se muestra el mapa de factor de expectativa; los valores usados fueron los mismos que en la prueba No.3. El entrenamiento de la red fue hecho en ciclos cortos, la arquitectura de la red neuronal artificial usada y la curva de error obtenida mientras la red fue entrenada, son mostradas en las Figuras 18 y 19 respectivamente; un grupo de 50000 combinaciones aleatorias fue generado, después de los filtros el número fue reducido a 39278 combinaciones posibles, los resultados para esta etapa son mostrados en la Figura 20 con círculos negros, con un porcentaje de error de 10%.



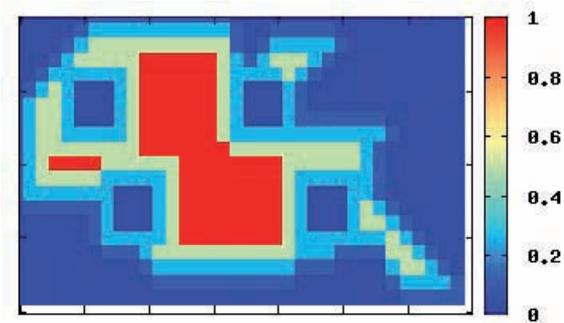
**Figura 15:** Modelo del yacimiento (35x20) para la prueba No.4: cajas amarillas , pozos existentes. Cajas rojas: Pozos de entrenamiento.

**Tabla 3:** Modelo usado en prueba No.4

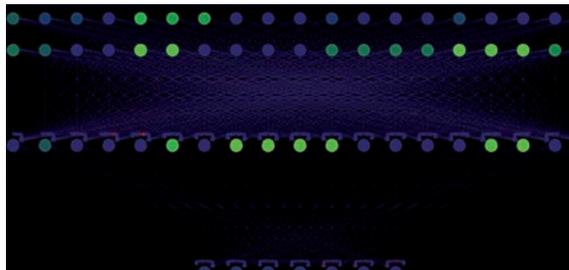
|                                |           |
|--------------------------------|-----------|
| Presión inicial del yacimiento | 6200 psia |
| Temperatura del yacimiento     | 144 °F    |
| Permeabilidad del yacimiento   | Figura 16 |
| Porosidad                      | 25%       |
| $\Delta x = \Delta y$          | 500ft     |
| Espesor del yacimiento         | 75ft      |
| Radio del wellbore             | 0.25ft    |



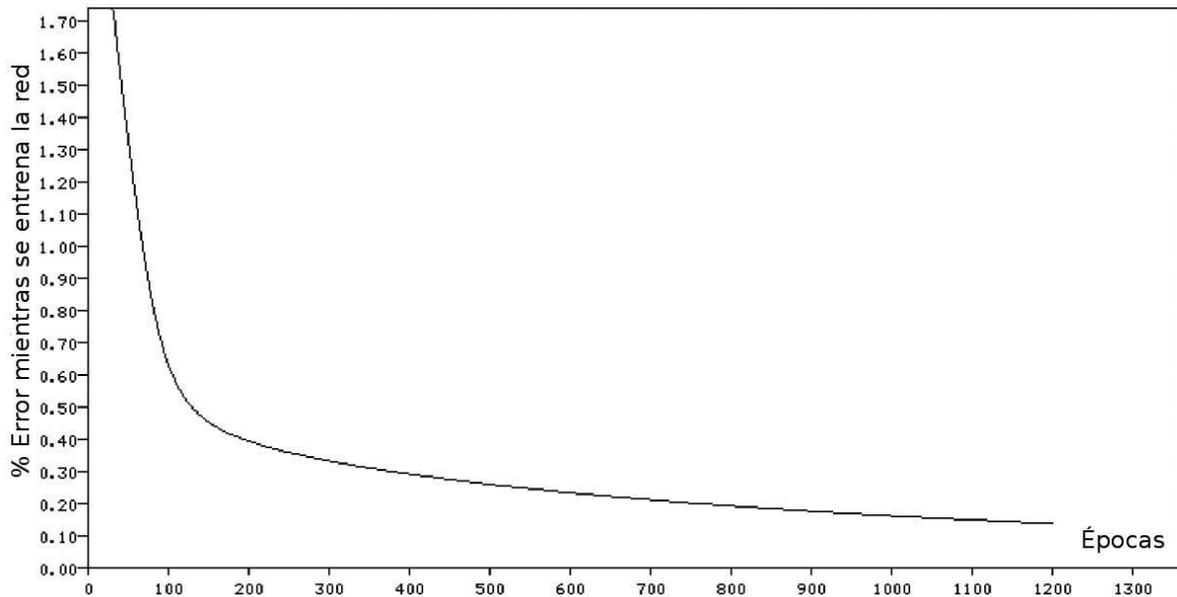
**Figura 16:** Mapa de permeabilidad para la prueba No.4.



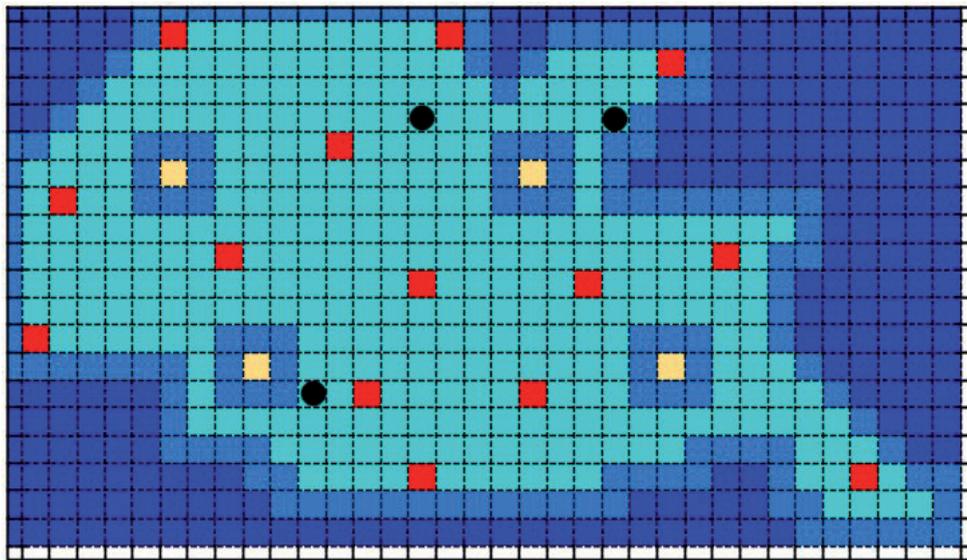
**Figura 17:** Mapa de factor de expectativa para la prueba No.4.



**Figura 18:** Arquitectura de la red neuronal artificial usada para la primera etapa de perforación, prueba No.4.



**Figura 19:** Curva de error para la primera etapa, prueba No.4.



**Figura 20:** Resultados para la primera etapa, prueba No. 4.

Para la segunda etapa, se mantuvo el mismo número y posiciones de los pozos de entrenamiento usados en la primera etapa, y el mapa de factor de expectativa fue cambiado debido a la inclusión de los 3 pozos nuevos, la arquitectura de la red es mostrada en la Figura 21 y la curva de error mientras se entrenó la red, se muestra

en la Figura 22. Después de que la red fue entrenada, se generó un grupo de 50000 combinaciones aleatorias y luego de los filtros el grupo fue de 38381 combinaciones posibles, los resultados para esta etapa se presentan en la Figura 23 en círculos verdes.

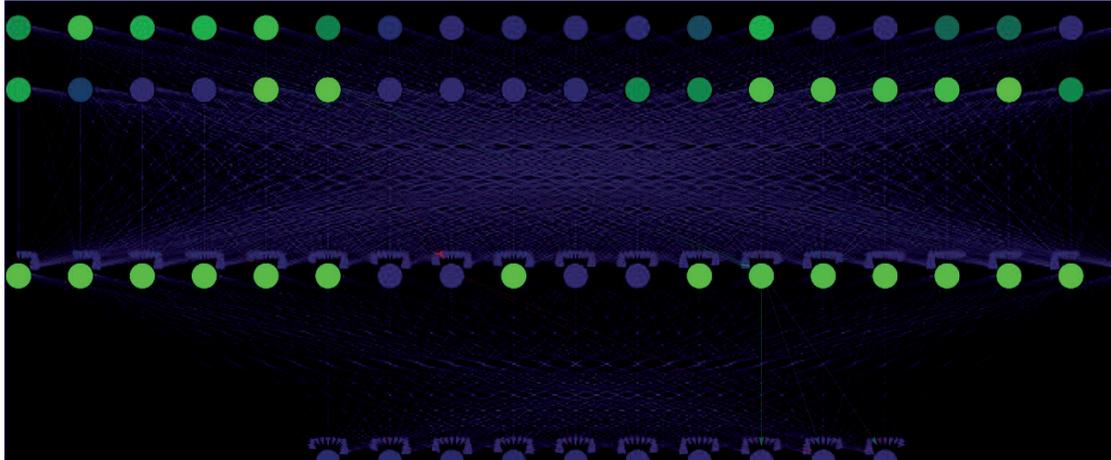


Figura 21: Arquitectura para la segunda etapa, prueba No.4.

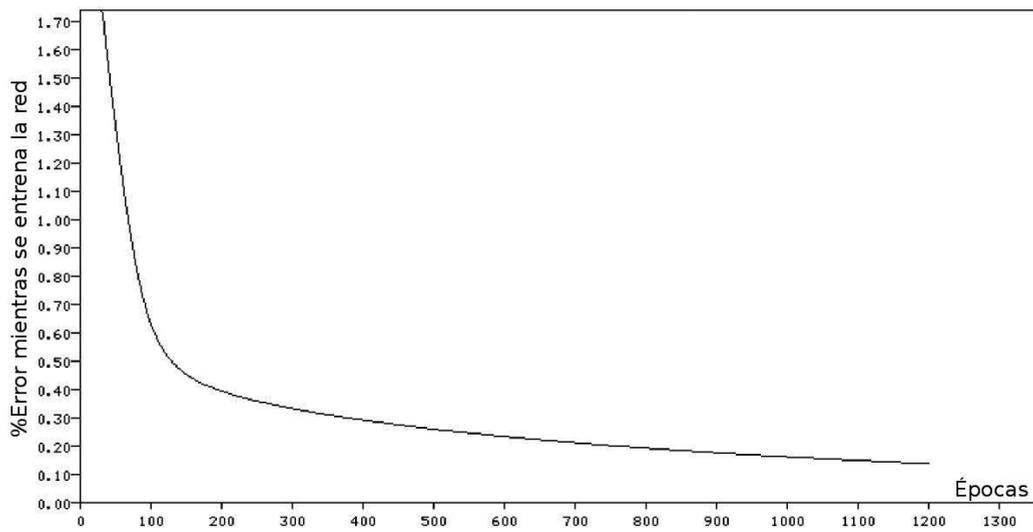


Figura 22: Curva de error para la segunda etapa, prueba No.4.

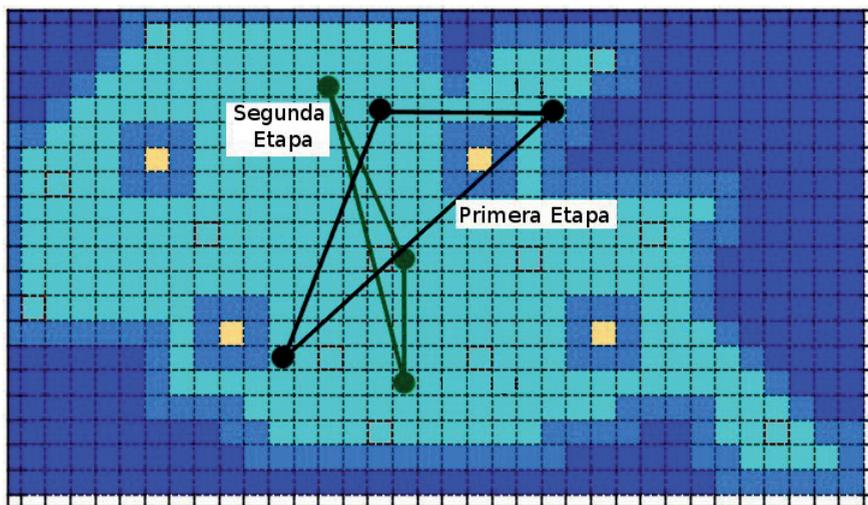


Figura 23: Resultados para la prueba No.4. Negro: Primera etapa. Verde: Segunda etapa.

## CONCLUSIONES

- El efecto de introducir heterogeneidad e irregularidad en los modelos de yacimiento afectan el funcionamiento de una red neuronal artificial convencional, para manejar este grado de complejidad, es requerido la inclusión de nuevas características que proveen mas información detallada del medio, como la permeabilidad, o variables que dan alguna clase de conocimiento experto a la red, como el factor de expectativa, o en un mejoramiento en la rutina de entrenamiento de la red. Típicamente en estos problemas se tiene que ajustar gradualmente los pesos sinápticos de la red. Además, a mayor nivel de heterogeneidad e irregularidad pueden ser la mayor tendencia de la red a fallar por sobreentrenamiento.
- El presente trabajo fue logrado por la aplicación de una metodología basada en una combinación de herramientas de libre distribución, la precisión de los simuladores de yacimientos, y el potencial de las redes neuronales artificiales para determinar la mejor posición de nuevos pozos en el desarrollo de campos que poseen heterogeneidad areal y forma irregular. Se sugiere que en trabajos siguientes se tenga en cuenta un número mayor de pozos en la configuración final y extender el análisis a más dimensiones.

## AGRADECIMIENTOS

Al Grupo de Investigación en Tecnologías Alternativas para Hidrocarburos -GITAH- dentro de la Universidad Industrial de Santander -UIS- por aportar y dar espacio y soporte para este trabajo.

## REFERENCIAS

1. Centilmen A., Ertekin T., y Grader A. "Applications of Neural Networks in Multiwell Field Development" – *SPE paper 56433, 1999 SPE Annual Technical Conference and Exhibition.*
2. Hazlett R. y Babu D. "Optimal Well Placement in Heterogeneous Reservoirs Via Semi-Analytic Modeling" – *SPE paper 84281, 2003 SPE Annual Technical Conference and Exhibition*
3. Institute for Parallel and Distributed High Performance Systems (IPVR) Stuttgart Neural Network Simulator, User Manual, Version 4.1
4. Mateus C. y Rojas D. Análisis y diagnóstico de problemas en el equipo de subsuelo de unidades de bombeo mecánico utilizando redes neuronales – *Tesis de Grado UIS 2007*

*Fecha de recepción: Julio de 2009*  
*Fecha de aceptación: Noviembre de 2009*