



MX0500279

XVI Congreso Anual de la SNM y XXIII Reunión Anual de la SMSR
XVI SNM Annual Meeting and XXIII SMSR Annual Meeting
Oaxaca, Oaxaca, México, Julio 10-13, 2005 / Oaxaca, Oaxaca, México, July 10-13, 2005

Optimización de Patrones de Barras de Control Usando Redes Neuronales

Dulce María Mejía Sánchez
Instituto Politécnico Nacional
Escuela Superior de Física y Matemáticas
Departamento de Ingeniería Nuclear
Avenida IPN s/n Colonia Lindavista C.P. 07738 México D.F.
dulcema6715@hotmail.com

Juan José Ortiz Servin
Instituto Nacional de Investigaciones Nucleares
Carretera México Toluca Km 36.5 Ocoyoacac Estado de México C.P. 52045
jjortiz@nuclear.inin.mx

Resumen

En este trabajo se presenta el sistema RENOPBC que está basado en una red neuronal recurrente multiestado, para la optimización de patrones de barras de control en un ciclo de equilibrio de un reactor de agua en ebullición (BWR por sus siglas en inglés). El diseño de patrones de barras está basado en el cumplimiento de los límites térmicos de operación, mantener crítico el reactor y que el perfil axial de potencia se ajuste a uno predeterminado a lo largo de varios pasos de quemado. Los patrones de barras de control propuestos por el sistema son equiparables a los propuestos por expertos humanos con muchas horas-hombre de experiencia. Estos resultados se comparan con los propuestos por otras técnicas como algoritmos genéticos, colonias de hormigas y búsqueda tabú para el mismo ciclo de operación. Como consecuencia se aprecia que los patrones de barras de control propuestos, tienen mayor facilidad de operación que los propuestos por las otras técnicas.

1. INTRODUCCIÓN

Las redes neuronales artificiales han sido utilizadas para realizar muchas tareas prácticas. La ingeniería nuclear también ha experimentado un auge en este sentido. En concreto se puede citar a Miller et al [1], quienes proporcionaron, en el año de 1992, las ideas básicas para el entrenamiento de una red neuronal que pudiera remplazar al simulador del reactor y posteriormente con un sistema experto optimizar la recarga de combustible.

Al siguiente año, Kim et al [2], entrenaron dos redes neuronales, una que predice la k_{ef} y la otra el pico radial de potencia en un reactor de agua a presión (PWR). En ese mismo año, Kim et al [3] acoplaron, las dos redes neuronales entrenadas, a una sistema experto para la optimización de la recarga de combustible en un PWR.

Jang et al [4], entrenaron una red neuronal, para algunos parámetros del reactor, como son: k_{ef} , pico radial de potencia, longitud de ciclo, potencia local, así como su quemado. Sadighi [5] utilizó una red neuronal de Hopfield para optimizar la recarga de combustible, de un reactor. Erdogan [6] entrenó una sola red neuronal, en el año de 2003, para predecir la potencia de todos los elementos combustibles y la k_{ef} del reactor. En el mismo año, Ortiz et al [7], entrenó una red neuronal para predecir los valores de los límites térmicos y k_{ef} al fin de un ciclo de operación. Un trabajo reciente es el de Ortiz [8], quien utiliza una red neuronal recurrente multiestado para optimizar la recarga de combustible en un BWR.

Esta ultima red, es la que se va a estudiar e implementar en este trabajo para la optimización de barras de control en un BWR.

2. DESCRIPCIÓN DEL PROBLEMA DE DISEÑO DE PATRONES DE BARRAS DE CONTROL

El núcleo de un BWR típico como los de la Central Nucleoeléctrica de Laguna Verde (CNLV) está formado por 444 canales de combustible y 109 barras de control. En la Figura 1 se muestra un cuarto de núcleo de este tipo de reactor en donde se marcan las barras de control de la Secuencia A2 con cruces y los canales se denotan con cuadros.

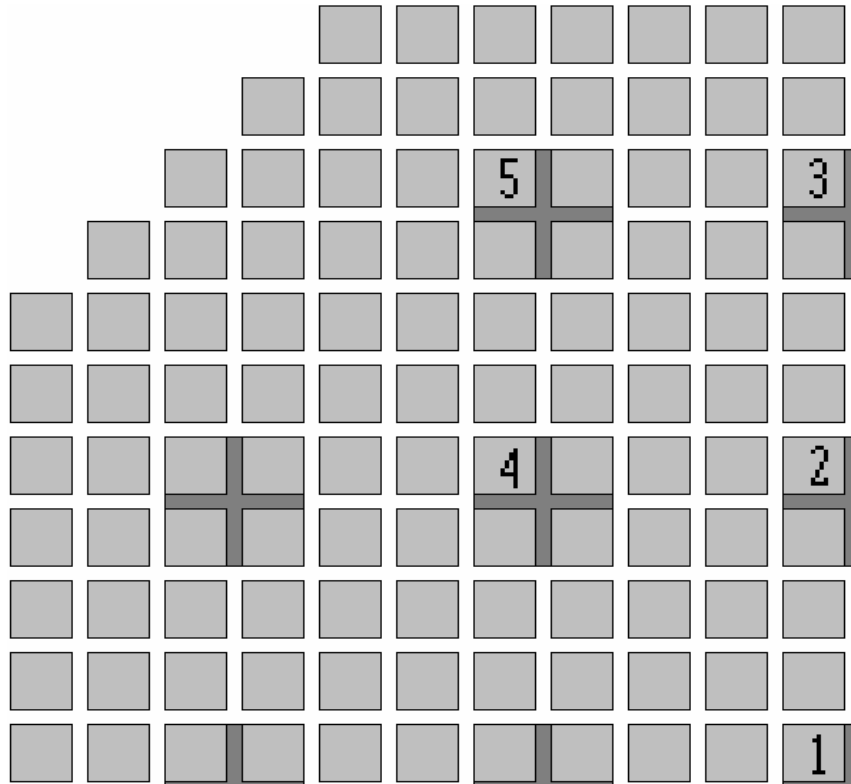


Figura 1. Mapa de ubicación de las barras de control en un cuarto de núcleo de un BWR.

En los reactores BWR las barras de control se insertan desde su parte inferior. Cada barra de control puede colocarse en 25 posiciones axiales diferentes. Estas posiciones axiales están etiquetadas con los números 00, 02, 04, ..., 48, siendo la posición 00 totalmente insertada; y la posición 48, totalmente extraída. A las posiciones en el rango 00 a 18 se les llama profundas y a las posiciones en el rango 32 – 48 se les llama someras.

El problema del diseño de los patrones de barras de control consiste en determinar la posición axial de todas las barras de control dentro del núcleo, de modo que se cumplan los siguientes requerimientos:

1. Verificar que los límites térmicos no se violen
2. Que el reactor se mantenga crítico
3. Que el perfil axial de potencia (PAP) sea lo más parecido a un perfil axial de potencia objetivo (PAPO)

La vida útil de una planta nuclear se divide en ciclos de operación que constan de una etapa de irradiación de combustible y otra de recarga. La etapa de irradiación del combustible se divide en pasos de quemado. Para cada paso de quemado se debe de diseñar un patrón de barras de control que cumpla con los requerimientos mencionados anteriormente. Al final de la etapa de irradiación las barras de control deben estar fuera del reactor.

El universo de posibles soluciones está dado por $[(25)^{109}]^N$, con N igual al número de pasos de quemado. Este número es tan grande que sería imposible analizar todas las soluciones, por ello se usan métodos de búsqueda no exhaustiva. Uno de estos métodos se describe en la siguiente sección. Es posible reducir el tamaño del universo de soluciones aplicando las siguientes simplificaciones:

1. Si la recarga de combustible se diseña con simetría de un octavo de núcleo, entonces también se puede diseñar el patrón de barras reduciendo de forma proporcional el número de barras.
2. Si la recarga de combustible se diseña siguiendo la estrategia de cargas Control Cell Core (CCC) [9], entonces solamente las barras de control de la secuencia A2 se utilizan. Esto implica la manipulación de 5 barras de control en un octavo del núcleo.
3. Las posiciones entre la 20 y la 30 se evitan, ya que distorsionan el perfil axial de potencia.

El universo de posibles soluciones con estas simplificaciones se reduce a $[(19)^5]^N$. Considerando $N = 12$ pasos de quemado, el universo de soluciones es de 5×10^{76} . Este número sigue siendo muy grande y de ahí la conveniencia de utilizar técnicas heurísticas que hagan una exploración adecuada del universo de soluciones.

3. REDES NEURONALES

La técnica de redes neuronales está basada en el funcionamiento del cerebro de un ser vivo donde las neuronas están conectadas entre sí. La comunicación de las neuronas tiene lugar como resultado de la liberación de unas sustancias llamadas neurotransmisores. Cada neurona envía impulsos a muchas otras neuronas (divergencia) y recibe impulsos procedentes de muchas neuronas (convergencia).

Las neuronas artificiales también están conectadas entre sí. Tienen muchas conexiones de entrada pero sólo una de salida. A cada una de estas conexiones se le asocia una magnitud llamada peso o intensidad de conexión. Para calcular el peso neto de todas las conexiones de entrada, se suman los valores de entrada ponderados mediante sus pesos correspondientes. Al resultado se le conoce como valor de activación. Con este valor se determina el valor de salida aplicando una función de salida (sigmoide, escalón o lineal). A la salida de una neurona se le conoce como estado neuronal.

Los pesos asociados a las conexiones, son inicialmente arbitrarios, por ello se debe llevar a cabo el ajuste de estos pesos, mediante el entrenamiento. Este entrenamiento consiste en darle a la red neuronal una serie de ejemplos de los cuales conocemos sus resultados correctos. De esta manera la red neuronal ajusta el valor de los pesos para poder dar la respuesta correcta al problema. Una vez que se ha entrenado la red neuronal, se le presenta un ejemplo que no haya visto durante su entrenamiento y será capaz de dar una respuesta adecuada.

Existen diversos tipos de redes neuronales, la que se usa en este trabajo es la red neuronal recurrente multiestado que se explica a continuación.

3.1. Red Neuronal Recurrente Multi Estado

Este tipo de red neuronal consiste de N neuronas conectadas entre sí. Cada neurona tiene asociado un estado neuronal, que puede tomar valores en el rango de 1 a M . En general $M \neq N$, sin embargo hay problemas en los que M puede ser igual a N . Cuando todas las neuronas tienen un estado neuronal asociado, se habla del estado global de la red. Es importante decir que este tipo de red neuronal no se entrena, sino que los pesos se predeterminan de acuerdo al comportamiento que se requiere de la red neuronal. En muchos problemas prácticos los pesos se inicializan con valor de uno.

Para el funcionamiento adecuado de este tipo de red neuronal, es necesario contar con una función de energía y una ley de transferencia.

La función de energía indica el nivel de energía del estado global de la red. La ley de transferencia le permite a las neuronas intercambiar estados neuronales entre ellas, de una manera ordenada. Por cada intercambio de estados, se evalúa la función de energía. Con esto se busca que el nivel de energía sea mínimo o máximo, dependiendo del objetivo.

El comportamiento de este tipo de red neuronal está basado en el enfriamiento de estructuras cristalinas. Cuando en la estructura hay muchos huecos, su estado de energía es alto. Por el contrario, cuando se disminuyen los huecos, su nivel de energía disminuye.

4. SISTEMA RENO-PBC

Para resolver el problema propuesto, se desarrolló un nuevo sistema de optimización de patrones de barras de control llamado RENO-PBC. Este sistema implementa las simplificaciones mencionadas en la Sección 2 utilizando una red neuronal recurrente multiestado. Este sistema fue desarrollado utilizando el lenguaje de programación Fortran, junto con el código Core Master

Presto (CMP) [10] para determinar el comportamiento del reactor bajo los patrones de barras propuestos.

La red neuronal recurrente multiestado consta de cinco neuronas, cada neurona representa a una barra de la secuencia A2 en un octavo de núcleo de acuerdo a la numeración mostrada en la Figura 1. Los estados neuronales toman valores en el rango de 0 a 48, en múltiplos de 2, de este modo el estado neuronal indica la posición axial de cada barra de control. La ley de transferencia funciona de la siguiente manera: se escoge una neurona al azar y sucesivamente se le asignan todos los estados neuronales posibles.

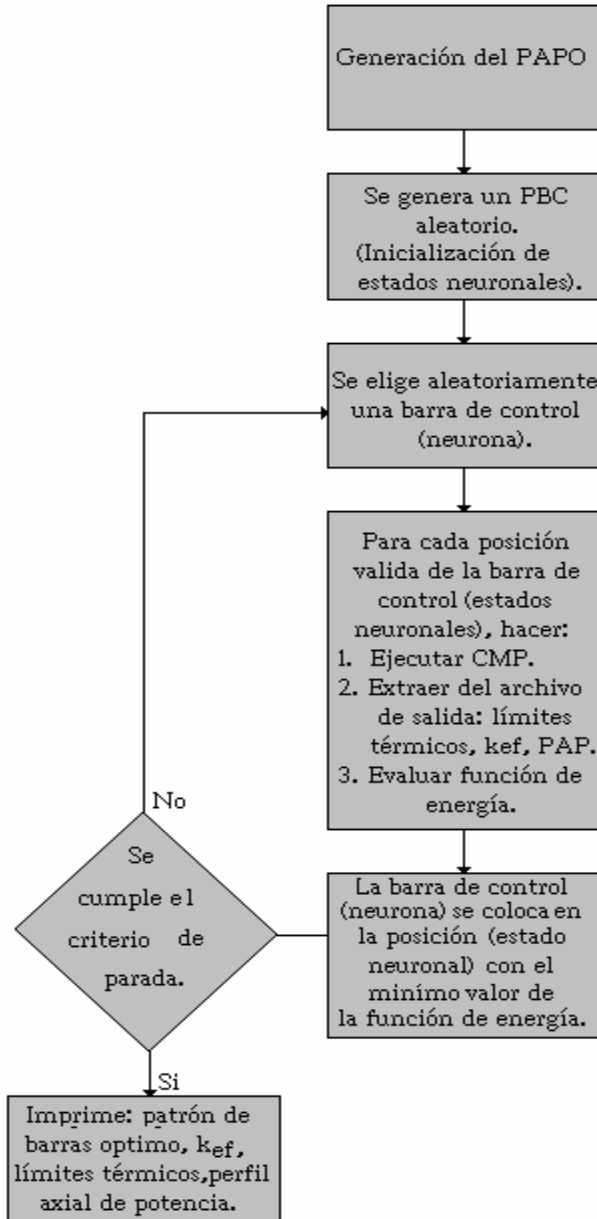


Figura 2. Diagrama a bloques del funcionamiento del sistema RENOPBC.

La función de energía utilizada en esta red neuronal tiene la siguiente forma:

$$FE = \sum_{i=1}^{25} \omega_1 (PAP_i - PAPO_i) + \omega_2 (k_{ef} - k_{Obj}) + \omega_3 (FLPD - 0.9) + \omega_4 (MPGR - 0.9) + \omega_5 (MFLCPR - 0.9) \quad (1)$$

donde:

ω_i	son factores de ponderación de variables.
PAP_i	es el Perfil Axial de Potencia en el i-ésimo nodo axial.
$PAPO_i$	es el Perfil Axial de Potencia Objetivo en el i-ésimo nodo axial.
k_{Obj}	es el valor objetivo de k_{ef} en el paso de quemado actual.
$FLPD$	es el límite térmico Fraction of Limiting Power Density.
$MPGR$	es el límite térmico Fraction of Limiting APLHGR.
$MFLCPR$	es el límite térmico Fraction of Limiting Critical Power Ratio.

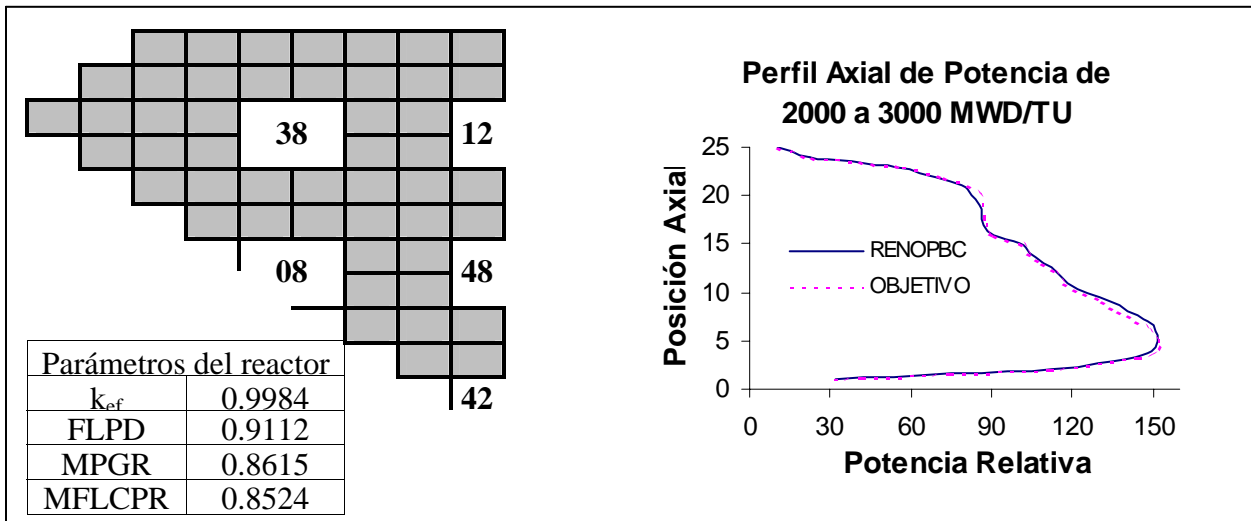


En la Figura 2 se presenta el diagrama de flujo del sistema RENOPBC. El patrón de barras de control generado aleatoriamente no debe de utilizar las posiciones intermedias (patrón válido). El diagrama presentado en la figura se repite para cada paso de quemado. Al inicio de un nuevo paso de quemado, el patrón de barras de control del paso previo, es introducido como patrón inicial. El criterio de parada es de 10 iteraciones. El PAPO se determina de acuerdo a la metodología dada en la referencia 12.

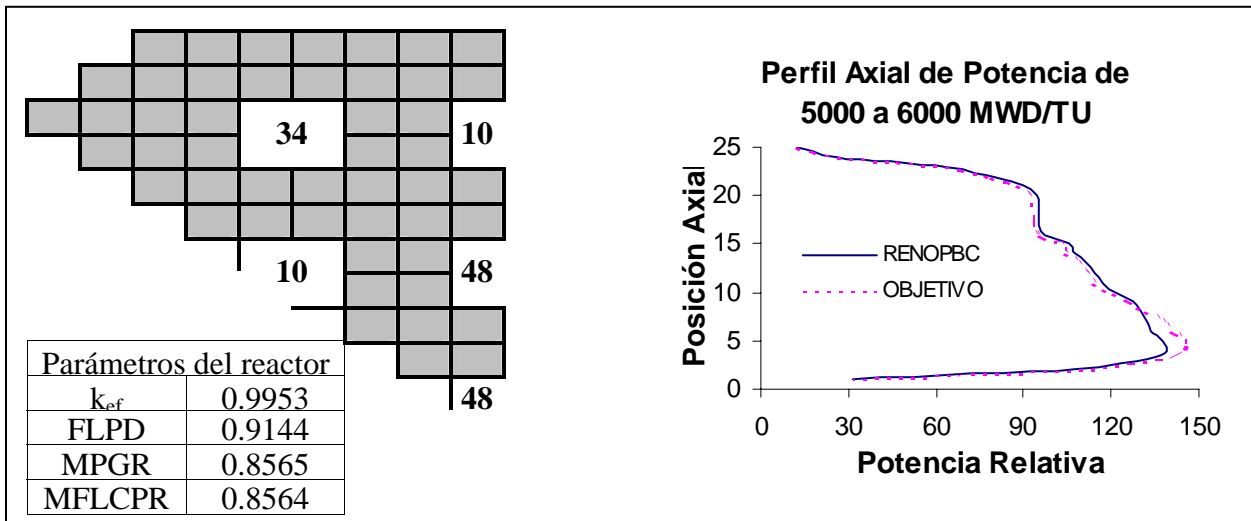
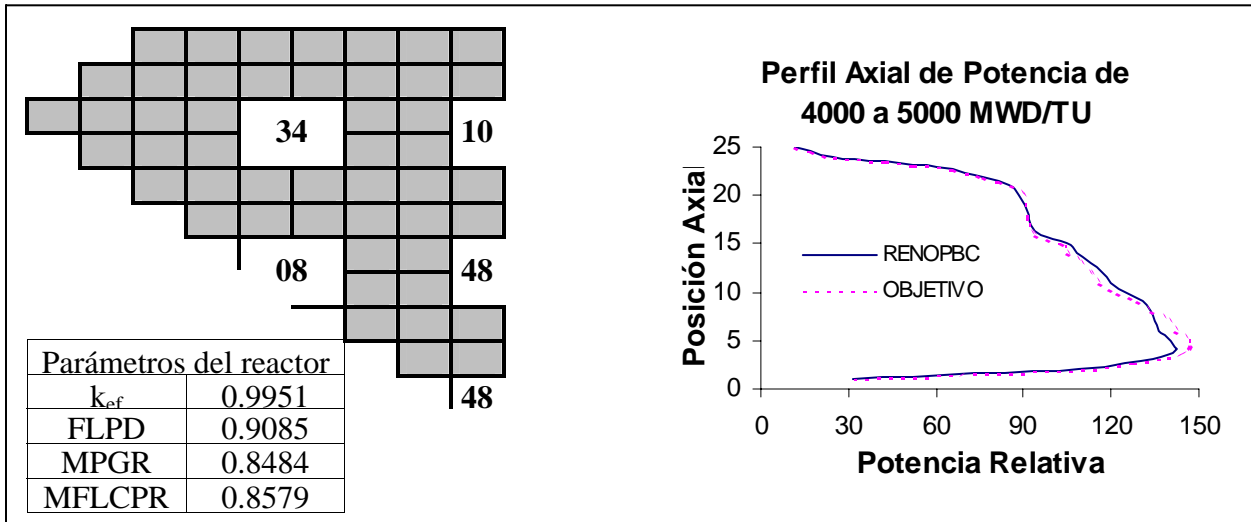
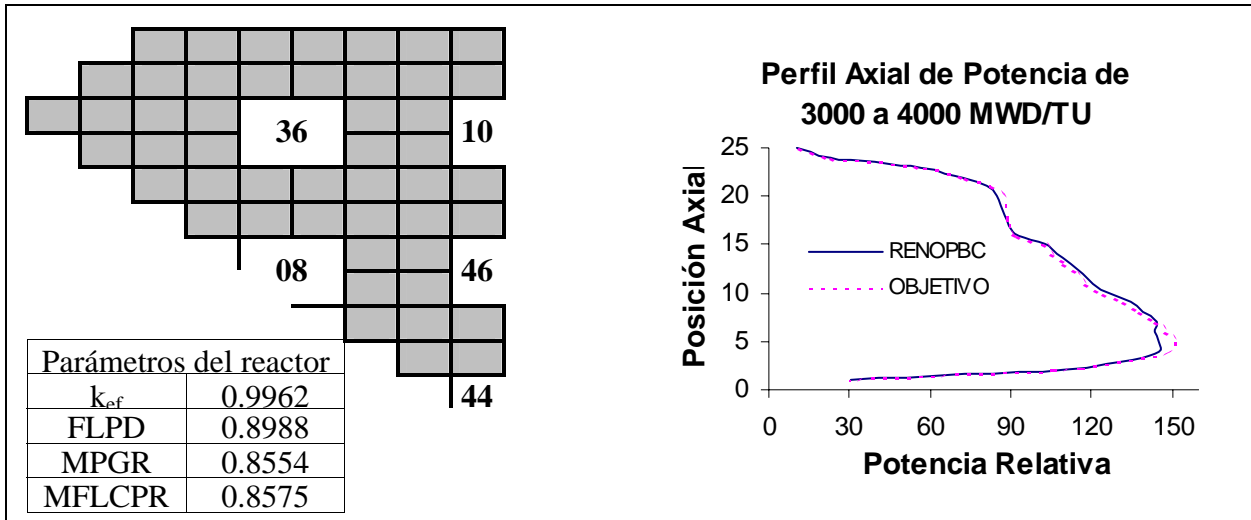
5. RESULTADOS



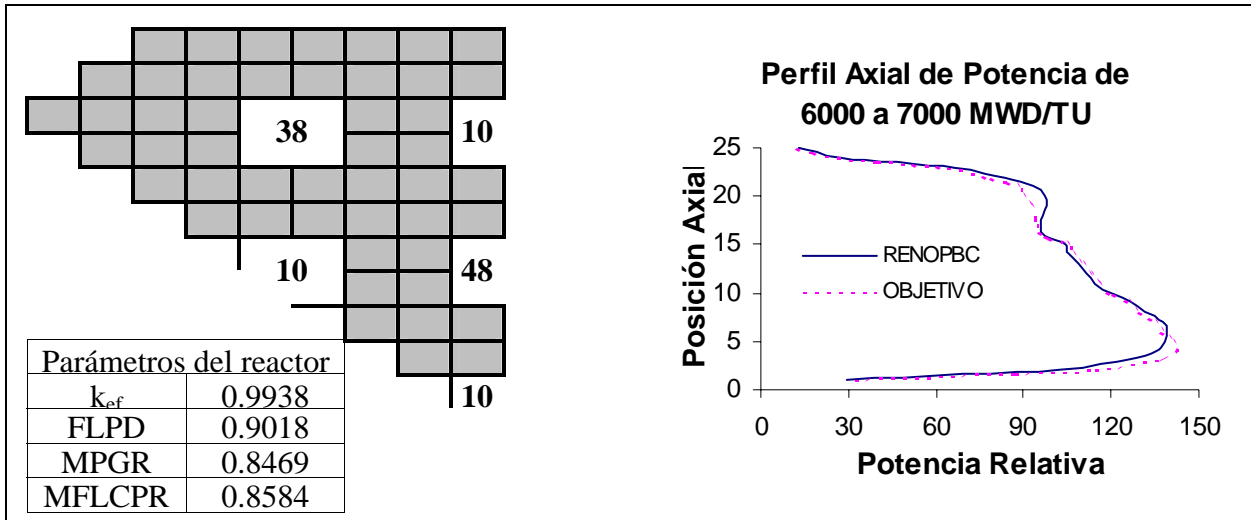
El sistema RENOPBC fue probado con un ciclo de equilibrio de 18 meses. El quemado total de dicho ciclo es de 11846 MWD/T [11] que incluye 10896 MWD/T de operación a plena potencia, quemado que es considerado como valor de referencia. El tiempo restante del ciclo es usado en las estrategias de operación de coastdown y de incremento de caudal. Este ciclo fue dividido en 11 pasos de quemado de 1000 MWD/TU y el último de 896 MWD/TU. El valor de k_{ef} al final de la operación a plena potencia, reportado por CM-PRESTO es de 0.9928 [11]. En este trabajo se fija el quemado en 10896 MWD/TU y se buscará superar o equiparar el valor de k_{ef} al final de la operación a plena potencia.

En la Figuras 3 se muestran resultados preliminares obtenidos por RENOPBC para el ciclo estudiado. En un octavo de núcleo, se muestran las cinco barras de control que empleamos y sus respectivas posiciones axiales, por cada paso de quemado, así como su respectiva gráfica del perfil axial de potencia comparado con el perfil axial de potencia objetivo.

El valor máximo permitido para las fracciones de los límites térmicos es de 0.93. Para hacer notar que los resultados obtenidos por RENOPBC están dentro de este rango, reportamos estos valores y el valor de la k_{ef} , por cada paso de quemado.







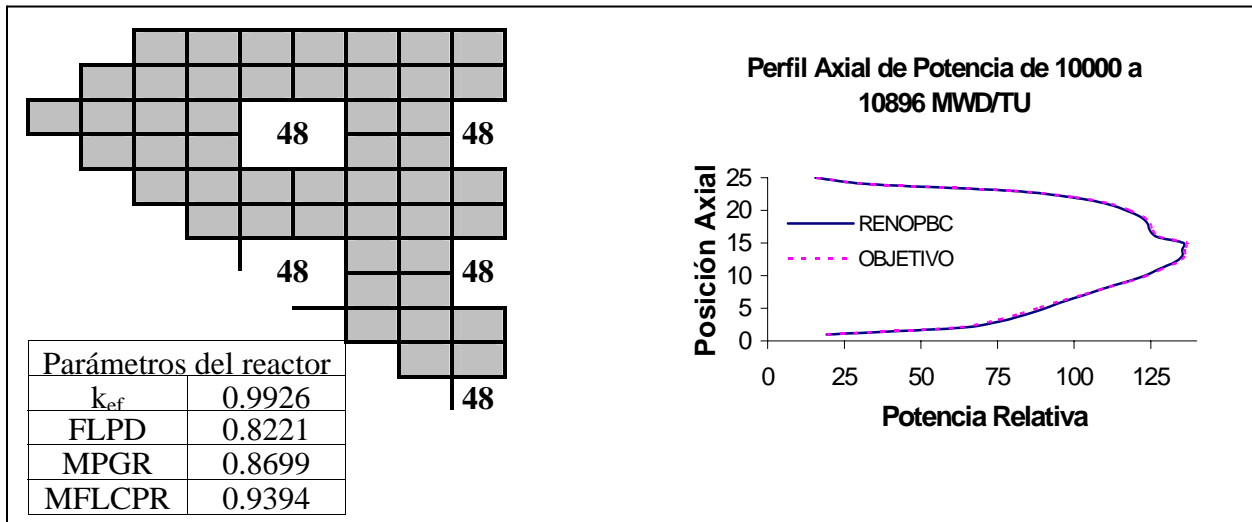



Figura 3. Patrón de barras de control, propuestos por RENOPBC, y su perfil axial por cada paso de quemado.

En términos generales, se tuvo buen comportamiento del perfil axial de potencia en todos los pasos de quemado. Se puede apreciar en esta figura, la tendencia del pico axial de potencia de desplazarse hacia la parte alta del núcleo a medida que transcurre el ciclo. Esto es debido a la formación de plutonio en la parte alta del núcleo y es una de las estrategias actuales de operación de reactores BWR, llamada *corrimiento espectral*.

El comportamiento de la k_{ef} con respecto al quemado del ciclo se muestra en la Figura 4. Se puede apreciar que la curva obtenida y la objetivo son muy parecidas, excepto hacia el final del ciclo donde se tiene una diferencias de 20 pcm por abajo del valor objetivo.

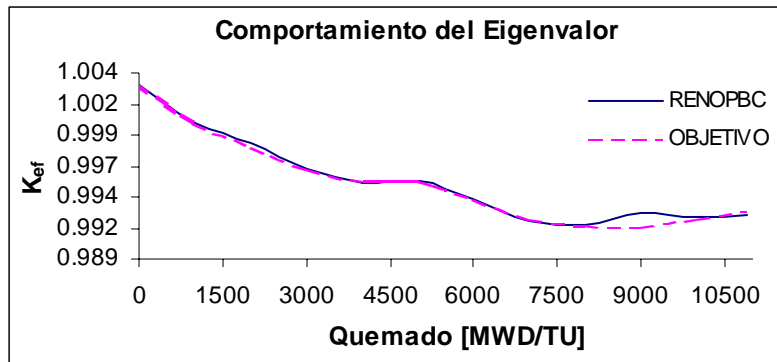


Figura 4. Comportamiento de la k_{ef} obtenida con los patrones de barras de control propuestos por RENOPBC comparada con la k_{ef} objetivo.

Encontramos que en el último paso de quemado, el límite MFLCPR nos da un valor arriba del máximo permitido. Sin embargo, el valor es aceptable ya que no es excesivo. Además como se trata del último paso de quemado y dado que se tiene la posibilidad de aumentar el caudal de agua a través del núcleo e inclusive meter alguna barra de control, pensamos que se puede mejorar dicho valor.

Con las técnicas de Algoritmos Genéticos (AG), Sistema de Colonias de Hormigas (SCH) y Búsqueda Tabú (BT) se estudió el mismo ciclo de equilibrio. En la Tabla I se muestra el valor de k_{ef} al fin de ciclo obtenida con cada técnica, así como la cantidad de movimientos de barras de control entre posiciones somero/profundas y de los movimientos de las barras de control a través del ciclo. En la Tabla II, se muestra el tiempo de CPU requerido para llevar a cabo una optimización con las técnicas mencionadas.

Tabla I. Movimientos de las barras de control.

Tipo de Movimientos	RENOPBC	AG	SCH	BT
Movimientos someros/profundos	5	13	16	16
Movimientos de barra	37	39	45	46
k_{ef} (EOR)	0.99264	0.99150	0.99290	0.99350

Tabla II. Tiempo de CPU de cada técnica.

Técnica	Tiempo
RENOPBC	1.6 hrs.
AG	5.1 hrs.
SCH	4.1 hrs.
BT	6.0 hrs.

De la Tabla I se puede apreciar que los patrones de barras de control propuestos por RENOPBC requieren menor cantidad de movimientos de barras de control que las otras técnicas. Esto repercute en una mayor facilidad de operación del reactor. Por otro lado, la energía generada con cada propuesta no difiere mucho entre ellas. La diferencia entre RENOPBC y búsqueda tabú es

menor al 0.1% y en cambio la conveniencia de tener un patrón más sencillo de operar es muy importante, aunado al menor tiempo requerido por RENOPBC con respecto a dicha técnica.

6. CONCLUSIONES

Se desarrolló un nuevo sistema basado en una red neuronal recurrente multiestado, para la optimización de barras de control. Los diseños propuestos por el sistema cumplen con las restricciones de seguridad impuestas y con la energía esperada del ciclo. La cantidad de movimientos de las barras de control es pequeña y resulta en una mayor facilidad de operación del reactor. Los resultados obtenidos son muy alentadores, por que la k_{ef} , al final del ciclo, con el programa RENOPBC tiene un valor de 0.99264 y la k_{ef} de referencia es de 0.9928, entre los cuales se tiene una diferencia de 16 pcm.

Es importante hacer notar que el ciclo estudiado para la realización de este trabajo, fue realizado por ingenieros nucleares con amplia experiencia. En contraparte, al sistema RENOPBC le toma pocas horas de trabajo para obtener resultados similares.

Una limitación que hemos observado en este sistema, es que como se utiliza una red neuronal con pocas neuronas (solamente 5), el resultado final depende en cierta medida de la primera neurona que se escoge para intercambiar su estado neuronal. Sin embargo, es necesario un estudio más completo para determinar la dependencia de los resultados en función del orden en que son escogidas las neuronas.

AGRADECIMIENTOS

Agradezco al Instituto Nacional de Investigaciones Nucleares por el apoyo recibido para la realización de este trabajo.

REFERENCIAS

1. L. F. Miller, F. Algutifan & R. E. Uhrig. "An Application of Neural Networks and Artificial Intelligence for In-Core Fuel Management". *Transactions of the American Nuclear Society*. **Vol. 66**. Pp 108-109. 1992.
2. H. G. Kim, S. H. Chang & B. H. Lee. "Pressurized water reactor core parameter prediction using an artificial neural network". *Nuclear Science and Engineering*. **Vol. 113(1)**. Pp. 70-76. 1993.
3. H. G. Kim, S. H. Chang & B. H. Lee. "Optimal fuel loading pattern design using an artificial neural network and a fuzzy rule-based system". *Nuclear Science and Engineering*. **Vol. 115(2)**. Pp 152-163. 1993.
4. C. S. Jang, H. J. Shim & C. H. Kim. "Optimization layer by layer for in-core fuel management optimization computations in PWRs". *Annals of Nuclear Energy*. **Vol. 28**. Pp 1115-1132. 2001.
5. M. Sadighi, S. Setayeshi & A. A. Salehi. "PWR fuel management optimization using neural networks". *Annals of Nuclear Energy*. **Vol. 29**. Pp 41-51. 2002.

6. Erdogan & M. Geçkinli. "A PWR reload optimisation code (XCore) using artificial neural networks and genetic algorithms". *Annals of Nuclear Energy*. **Vol. 30(1)**. Pp 35-53. 2003.
7. J. J. Ortiz & I. Requena. "Using Neural Networks to Predict Core Parameters in a Boiling Water Reactor". *Nuclear Science & Engineering*. **Vol. 143(3)**. Pp. 254-267. 2003.
8. J. J. Ortiz & I. Requena. "Using a Multi-State Recurrent Neural Network to Optimize Fuel Reloads in BWRs". *Annals of Nuclear Energy*. **Vol. 31**. Pp. 789-803. 2004.
9. S. R. Specker, L. E. Fennern, R. E. Brown, K. L. Stark & R. L. Crowther. "The BWR Control Cell Core Improved Design". *Transactions of American Nuclear Society*. **Vol. 30**. Pp 336-338. 1978.
10. Scandpower AS. "User Manual CM-Presto 9. Version CM914B". Rev. 6, July 16, 1993.
11. Montes J.L., Perusquía R., Hernández J.L., 2001. Estudio del Ciclo de Equilibrio de 18 meses para la CLV con combustible 10x10 usando el simulador 3D CM-PRESTO. *Memorias del XII Congreso Anual de Sociedad Nuclear Mexicana*. Zacatecas, México. 8 – 10 Octubre de 2001.
12. J. L. Montes, J. J. Ortiz, I. Requena and R. Perusquía. "Searching for full power control rod patterns in a boiling water reactor using genetic algorithms". *Annals of Nuclear Energy*. **Vol. 31 (16)**, Pp. 1939-1954. 2004, November.