

# Predicción de la temperatura de la contención primaria de una central nuclear mediante redes neuronales



Antonio Álvarez-Huerta\*  
Rodrigo González-Miguel\*  
David García-Metola\*\*  
Álvaro Noriega-González\*\*\*

Ingeniero Industrial  
Ingeniero Industrial  
Licenciado en Física  
Dr. Ingeniero Industrial

\* NUCLENOR. Sección Operación y \*\* Ingeniería de Planta. Central Nuclear Sta. M<sup>a</sup> de Garoña – 09212 Burgos. Tfno: +34 947 349400. antonio.alvarez@nucenor.es; rodrigo.gonzalez@nucenor.es; david.garcia@nucenor.es

\*\*\* UNIVERSIDAD DE OVIEDO. Área de Ingeniería Mecánica. Edificio Departamental Oeste. Módulo 5. Campus de Viesques, s/n - 33203 Gijón. Tfno: +34 985 182469. noriegalvaro@uniovi.es

Recibido: 09/12/2010 • Aceptado: 21/03/2011

## *Drywell temperature prediction of a nuclear power plant by means of artificial neural networks*

### ABSTRACT

- In a nuclear power plant, Drywell atmosphere temperature is an important operating parameter, for which technical specifications in each power plant set a limit in normal operation. This limit is an initial condition in the analysis of safety requirements. Specifically, in Santa María de Garoña's power plant, this temperature has an upper limit in normal operation of 58 °C. The cooling system installed to remove the heat produced inside the Drywell consists mainly of refrigeration units (3), pumps (2), and heat exchangers or HVH equipments (5). The pump in service drives the coolant (demineralized water) previously cooled by refrigeration units in service (2), which flow through the battery of the 5 heat exchangers, cooling Drywell atmosphere, which is inerted with nitrogen. Thus, the heated coolant returns to the refrigeration units completing the circuit. In case of unavailability of any HVH in service, it would occur a slight increase in average Drywell temperature. This article shows the use of neural networks to predict the evolution of Drywell atmosphere temperature against the variation of different variables that influence it, such as service water temperature (cold sink of the system), the setting of the compressors of the refrigeration units, the core flow and the number of HVH working. Neural networks used in this article incorporate all historical knowledge stored about the different ways of cooling system operation for the Drywell atmosphere temperature, and they show high accuracy in predicting that temperature. Thereby, they are a useful tool for taking decisions over the operating point of the system.
- **Keywords:** nuclear power plant, cooling system, Drywell temperature, artificial neural network.

### RESUMEN

En las centrales nucleares, la temperatura de la atmósfera de Contención Primaria es un parámetro operativo relevante, para el cual las Especificaciones Técnicas de Funcionamiento de cada instalación fijan un valor límite en operación normal. Dicho límite es una condición inicial en los análisis de seguridad aplicables. En el caso de la *Central Nuclear de Santa María de Garoña* el límite para la temperatura media de la atmósfera de Contención Primaria en operación normal es de 58 °C. El sistema de refrigeración instalado para extraer el calor que se produce en el interior de la Contención consta principalmente de grupos frigoríficos (3), bombas (2), y climatizadores o equipos HVH (5). La bomba en servicio impulsa el fluido refrigerante (agua desmineralizada) previamente refrigerado por los grupos frigoríficos en servicio (2), que circula por las baterías de los 5 climatizadores refrigerando la atmósfera de la Contención, la cual está inertizada con nitrógeno. De esta manera, el fluido refrigerante calentado retorna a los grupos frigoríficos completando así el circuito. En caso de indisponibilidad de los climatizadores en servicio, se produciría un ligero aumento en la temperatura media de la Contención.

En este artículo se muestra el uso de redes neuronales para predecir la evolución de la temperatura de la atmósfera de Contención ante la variación de las distintas variables que influyen en la misma, como son la temperatura del agua de servicios (foco frío de los grupos frigoríficos), los tarados de temperatura de los compresores de los grupos frigoríficos, el caudal del núcleo y el número de climatizadores en servicio.

Las redes neuronales utilizadas incorporan todo el conocimiento histórico almacenado de los distintos modos de

funcionamiento del sistema de refrigeración de la atmósfera de la Contención y muestran una elevada exactitud en la predicción de la temperatura de la Contención Primaria, configurándose así como una herramienta operativa muy útil para la toma de decisiones sobre el punto de funcionamiento del sistema.

**Palabras clave:** central nuclear, sistema de refrigeración, temperatura de contención primaria, red neuronal artificial.

## 1. INTRODUCCIÓN

La Contención Primaria conocida también como *Drywell*, es la estructura de contención en torno al reactor y a su sistema de recirculación en reactores de agua en ebullición. Normalmente es una estructura cilíndrica de hormigón armado con una tapa extraíble de acero para poder acceder a la vasija del reactor en situación de recarga (Figura 1). Proporciona un sistema de reducción de la presión en caso de accidente con pérdida de refrigerante (LOCA), dirigiendo el vapor liberado hacia la piscina de supresión donde se produciría la condensación del vapor, además de ser una barrera para los productos de fisión [1], con lo cual, supone, además, una barrera efectiva para la seguridad nuclear, del público en general y del medioambiente.

La temperatura de la Contención Primaria debe mantenerse en operación normal por debajo de 58 °C por Especificaciones Técnicas de Funcionamiento [2], ya que se trata de una de las hipótesis de partida para que en el caso

de producirse un LOCA, esté asegurada la refrigeración del núcleo mediante los sistemas de seguridad.

La Contención es refrigerada mediante 5 climatizadores (HVH), cada uno de los cuales consta de una batería de frío (por donde circula el fluido refrigerante impulsado por la bomba correspondiente tras su paso por los dos grupos frigoríficos en servicio) y por un ventilador que impulsa  $N_2$  enfriado a la atmósfera tras el intercambio con el fluido refrigerante en la batería de frío. Para enfriar de nuevo el fluido refrigerante calentado tras el intercambio de calor, se dispone de tres grupos frigoríficos (dos en servicio y uno en reserva) por cuyos condensadores circula agua procedente del sistema de agua de servicios, la cual es tomada del río Ebro, el foco frío del sistema. Puede verse un esquema del sistema en la Figura 2:

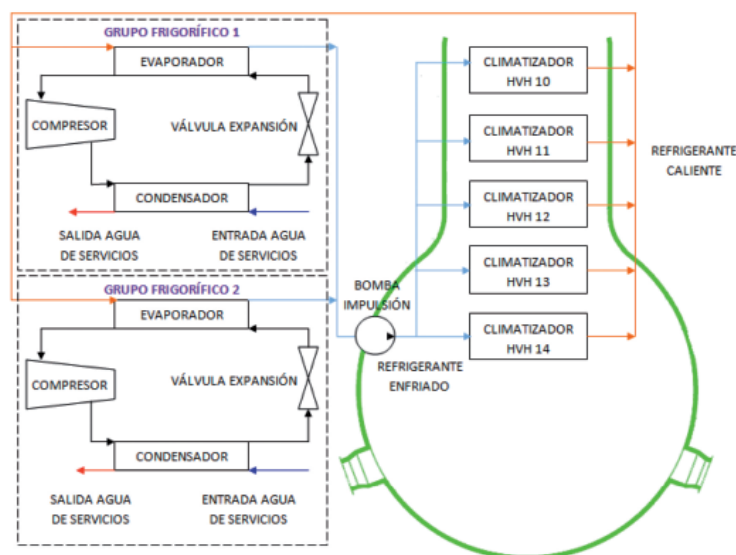


Figura 2: Esquema de refrigeración de la Contención

Desde el año 1980 en el que se sustituyeron los climatizadores originales, se han producido indisponibilidades en los mismos por diferentes motivos (rotura de correas, deterioro de rodamientos y sus soportes, ejes, etc.), lo que ha dado lugar a distintas modificaciones como son la sustitución del modelo de los rodamientos, aumento del número de correas, nuevos ejes, disminución del tensado de las correas, sustitución de dos unidades por un nuevo diseño de accionamiento directo, etc.

La indisponibilidad de dos de estos climatizadores conlleva la necesidad de reducir potencia para disminuir la carga térmica en la Contención, que tiene un límite por Especificaciones Técnicas de Funcionamiento de 58 °C, lo que implica la programación de una parada de la unidad para recuperar la disponibilidad de los climatizadores y recuperar así la plena potencia.

Actualmente, no se dispone de ningún método de predicción de esta temperatura en función de las condiciones esperadas en el foco frío y de operación, ya que las condiciones de funcionamiento operativo seguro, reguladas




Figura 1: Vista en alzado de la Contención Primaria

en [3], simplemente recogen especificaciones para rebajar la potencia de la central cuando la temperatura de la contención primaria se aproxima a 58 °C.

Los parámetros más importantes que determinan el punto de funcionamiento del sistema de refrigeración de la Contención Primaria son la temperatura del agua de servicios, el caudal del núcleo del reactor (en adelante caudal del núcleo), el número de climatizadores en servicio y el tarado de los compresores de los grupos frigoríficos. El caudal del núcleo, encargado de extraer el calor del combustible y permitir además la variación de potencia sin el movimiento de las barras de control, es impulsado mediante las bombas del sistema de recirculación, cuyo funcionamiento supone una carga térmica para la Contención Primaria, ya que se encuentran allí alojadas. El tarado de los compresores regula la temperatura de entrada del fluido refrigerante a los climatizadores en servicio, alcanzando dicha temperatura valores más o menos próximos a la de tarado, en función de la del agua de servicios.

La predicción de la temperatura de Contención Primaria en función de tales parámetros podría realizarse a través de un modelo analítico que tuviera en cuenta todo el sistema de refrigeración de la contención. No obstante, para utilizar este modelo es necesario conocer una serie de parámetros reales (coeficientes de transmisión, película, etc.) de los cuales no se dispone, además de que el modelo sería muy complejo.

Sin embargo, se dispone de gran cantidad de datos recopilados durante los años de funcionamiento de la central. En base a estos datos, una alternativa factible para modelizar la evolución de la temperatura de la Contención Primaria es el uso de modelos de tipo polinómico (regresiones polinomiales) [4] o de redes neuronales artificiales (RNA). Estos modelos presentan la ventaja de una menor complejidad y mayor eficiencia en su computación respecto al modelo analítico antes comentado, el cual, además, necesitaría la experimentación real para validarlo.


La ventaja de los primeros es que son estructuralmente

sencillos, ya que solo hay que decidir el grado del polinomio y el número de variables. Sin embargo, su desventaja es que la calidad de los modelos obtenidos depende en gran medida de la elección de las variables y del grado del polinomio, solo permiten modelizaciones de alta precisión a nivel local y su precisión no puede mejorarse añadiendo términos de orden superior porque se produciría un sobreajuste. En el caso de las RNA, su principal ventaja es que no tiene un modelo preconcebido sobre el fenómeno a estudiar, lo cual les permite una alta flexibilidad y una mejor adaptación a modelos complejos o de comportamiento global. Como a priori no se dispone de una idea clara de la complejidad del modelo que relaciona la temperatura de contención primaria con los parámetros de funcionamiento del sistema de refrigeración antes enunciados, se ha elegido a las RNA como método de modelización a usar en este estudio.

Una vez obtenido y validado el modelo a través de la RNA, se puede predecir la evolución de la temperatura de la Contención Primaria en distintas situaciones operativas como cambios de secuencia del modelo de barras de control, requeridos por la gestión del núcleo (lo que implica una variación del caudal del núcleo), variaciones del caudal del río por la gestión de los dos embalses entre los que está situada la central o predicciones de olas de calor o de frío (ambas tendrían efectos en la temperatura del agua de servicios, el foco frío del sistema), indisponibilidad de algún climatizador de la Contención o variaciones en los tarados de los compresores de los grupos frigoríficos, con lo que las ventajas operativas de tener un modelo preciso son evidentes a la hora de predecir cuál será el valor final de la temperatura de Contención tras una maniobra operativa como las descritas con anterioridad.

A la hora de implementar la red presentada en este artículo, no se ha podido aprovechar todo el potencial de la base de datos, ya que se presentan casos de funcionamiento del sistema de refrigeración de la Contención con especificaciones técnicas utilizadas actualmente, más

## USO DE LAS REDES NEURONALES ARTIFICIALES



Las RNA se suelen utilizar para modelizar fenómenos complejos de los que se dispone únicamente de resultados experimentales, pero no del modelo matemático en el que se basan. En el ejemplo mostrado en la figura de este cuadro se puede ver la función de Branin de dos variables modelizada con una RNA de 8 neuronas en la capa oculta a partir de 100 experimentos generados aleatoriamente. Los experimentos usados para el entrenamiento se representan mediante círculos coloreados.

Como se puede apreciar en la distribución de los experimentos, la función es bastante compleja, pero la RNA se ajusta con gran precisión a su topología. Si se intenta realizar el ajuste de los experimentos mediante un modelo polinomial, se obtienen unos indicadores de la calidad del ajuste muy malos que indican la no idoneidad de dicho método para este caso.



eficientes a las empleadas con anterioridad. Por lo tanto, se emplea un número reducido de datos que coincide con el funcionamiento actual del sistema.

## 2. METODOLOGÍA

El trabajo se ha basado en la aplicación de redes neuronales artificiales para la predicción de la temperatura del *Drywell*, ya que se ha demostrado en numerosas aplicaciones de ingeniería (control de procesos, robótica, toma de decisiones, tribología, etc.) que pueden aproximar funciones con un alto grado de exactitud [5,6,7]. En el marco de las RNA, la red neuronal multicapa estática es, en la actualidad, una de las arquitecturas más utilizadas para la resolución de problemas, debido fundamentalmente a su capacidad como aproximador universal, fácil uso y comodidad [8].

Las RNA multicapa estáticas utilizadas en este trabajo constan de una capa de entrada, en la cual hay tantos nodos como variables de entrada; tiene el problema, en nuestro caso, la temperatura del agua de servicios y el caudal del núcleo (Figura 3).

A continuación de la capa de entrada, hay una o varias capas, denominadas capas ocultas (en nuestro caso hay una), formadas por las neuronas propiamente dichas. Estas neuronas están conectadas con todos los nodos o neuronas de la capa inmediatamente anterior a través de conexiones llamadas sinapsis. Las neuronas responden al modelo indicado en la ecuación (1):

$$x_j^k = f\left(\sum_{i=1}^n \omega_{ji}^k \cdot x_i^{k-1} + b_j^k\right) \quad (1)$$

Donde  $k$  representa el número de la capa,  $x_i^k$  es la salida de la neurona  $i$  de la capa  $k$ ,  $\omega_{ji}^k$  es el peso asignado en la neurona  $j$  de la capa  $k$  a la entrada procedente de la neurona  $i$  de la capa anterior,  $b_j^k$  es la tendencia, y el  $n$  es el número de neuronas de una capa. La función  $f$  (función de activación) de cada neurona puede ser de distintos tipos: escalón, lineal, logarítmica sigmoideal o tangente sigmoideal. Lo habitual es que todas las neuronas de una capa tengan la misma función de activación. La tendencia  $b$  desempeña un papel similar al término independiente en un polinomio, ya que permite añadir valores constantes a la salida aunque las entradas sean cero. El valor de esa entrada constante a cada neurona es 1 y el valor del peso que se le aplica  $b_j^k$  se ajusta de manera similar a los  $\omega_{ji}^k$  durante el entrenamiento.

Finalmente, hay una capa de salida formada por tantas neuronas como salidas tenga la RNA. En nuestro caso, tenemos una salida, la temperatura en la Contención Primaria.

Para la elección del número óptimo de neuronas de la capa oculta, se ha partido de las recomendaciones de Lippman [9] y se ha realizado una experimentación con distintos números de neuronas hasta obtener valores de error pequeños y buena capacidad de generalización. Se ha utilizado una red

con 2 o 3 neuronas en la capa oculta, dependiendo del caso estudiado, como se verá más adelante.

CAPA DE ENTRADA    CAPA OCULTA    CAPA DE SALIDA




Figura 3: Arquitectura de la red diseñada

El algoritmo de aprendizaje empleado recibe el nombre de retropropagación, debido a la forma de implementar el método del gradiente para obtener los pesos óptimos de las conexiones entre neuronas, pues el error cometido en la salida de la red es propagado hacia atrás, transformándolo en un error para cada una de las neuronas ocultas [8,11]. Basándose en el error recibido, se reajustan los pesos de conexión de cada neurona, de manera que la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada, es decir, que el error disminuya [12].

La RNA se ha implementado en el entorno MATLAB, usando una función de activación tangente sigmoideal para la capa oculta, y una lineal para la capa de salida, y empleando el método de *Levenberg-Marquardt* como método de entrenamiento, ya que presenta una velocidad de convergencia hacia el error cuadrático medio (MSE) muy rápida, principalmente en problemas de aproximación de funciones. Dicho método emplea el concepto de la *regla Delta* generalizada y aplica el procesamiento por lotes como modo de entrenamiento. El gradiente se calcula mediante la matriz Jacobiana de los errores de las neuronas de salida, y es esta matriz la que hace que se tenga una convergencia más rápida, incluso 100 veces superior que la obtenida por el descenso por gradiente convencional [13].

Se han considerado caudales de núcleo superiores al 87% del caudal de diseño, ya que estos valores son los que resultan importantes desde el punto de vista operativo, además de considerar unas pérdidas térmicas del reactor constantes para estos valores, en torno a 0,7 MW térmicos. El caudal del agua de servicios que llega al condensador es constante en condiciones normales de funcionamiento. Se han recogido datos en situaciones donde los climatizadores HVH funcionan a su potencia nominal, reduciendo de esta manera el número de variables a introducir a la red (caudal de  $N_2$  impulsado), ya que esa es su situación habitual de trabajo.

Cabe destacar que la temperatura de la Contención Primaria, es una media ponderada de doce temperaturas diferentes, obtenidas a partir de doce sensores colocados en

posiciones estratégicas con diferente altura y ángulo azimutal. Por lo tanto, se adaptan los datos que se introducen a la red neuronal como patrón objetivo, considerando realmente una temperatura media de la atmósfera de la Contención Primaria calculada según [14]. El caudal del núcleo se introduce en porcentaje en vez de caudal volumétrico, por ser éste un formato más útil desde el punto de vista operativo.

Los datos utilizados no se han normalizado, ya que no es estrictamente necesario, debido a la estructura de la red empleada [8] y al no darse problemas numéricos de mal condicionamiento del jacobiano durante el entrenamiento [15] que afecten a la precisión de la predicción. Si en vez de una función de transferencia lineal para la capa de salida, se hubiera empleado en su lugar, por ejemplo, una sigmoidea, hubiera sido necesario normalizar los datos introducidos como patrón objetivo (temperatura de la Contención), al estar restringida la salida de esta función al rango [0,1]. El algoritmo de entrenamiento utilizado (el *método de Levenberg-Marquardt*) es invariante respecto a la escala de los datos. Si se hubiera utilizado otro algoritmo que durante el entrenamiento hubiera dado problemas de mal condicionamiento y la precisión de la red no fuera adecuada, podría ser necesario normalizar entonces los datos introducidos como patrones de entrada (caudal del núcleo y temperatura del agua de servicios).

De la base de datos históricos de la central, se han seleccionado dos conjuntos diferentes, uno para el entrenamiento y otro para el test de la red [6,8], con los experimentos distribuidos lo más uniformemente posible. El entrenamiento representa aproximadamente en cada caso el 85 % de los datos totales, mientras que el porcentaje restante lo representa el conjunto de test. Para mejorar la generalización de la red, se utiliza la detección temprana, cogiendo para cada caso un tercer subconjunto, el de validación, que es aproximadamente un 15 % del conjunto de entrenamiento.

Para valorar la calidad de la predicción, se utilizan dos indicadores [16], el error medio relativo (R) y el coeficiente de determinación (B), aplicados al conjunto de test:

$$R = \frac{1}{s} \sum_{c=1}^s \frac{|Op_c - O_c|}{O_c} \quad (2)$$

$$B = 1 - \frac{\sum_{c=1}^s (Op_c - O_c)^2}{\sum_{c=1}^s (Op_c - O_{ave})^2} \quad (3)$$

Siendo  $Op_c$  el valor de la predicción de la red,  $O_c$  el valor medido,  $O_{ave}$  el valor medio de las mediciones, y  $s$  el número de datos para del conjunto de entrenamiento, validación o test. En teoría, valores de R próximos a 0 indican una mejor predicción de la red neuronal, así como valores de B próximos a 1.

En la figura que se muestra a continuación (Figura 4), se puede ver el proceso de construcción de la red descrita anteriormente:

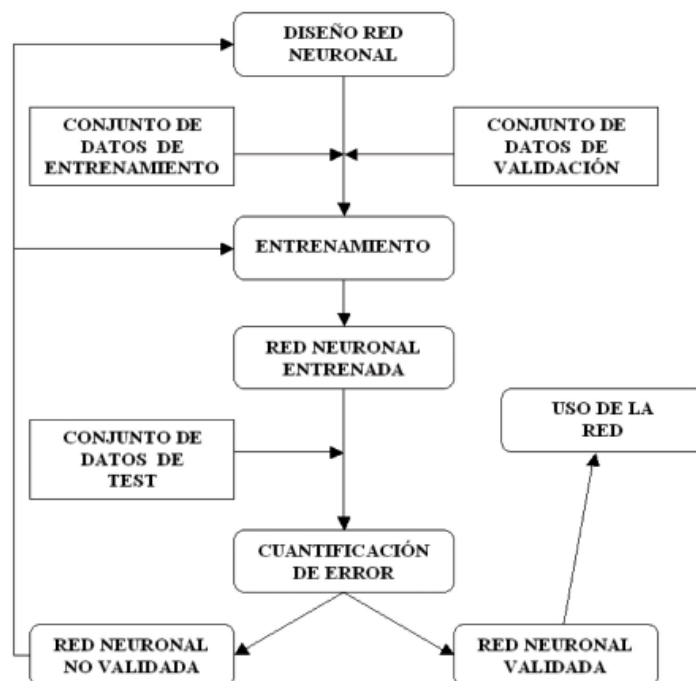


Figura 4: Proceso de construcción de una red neuronal con generalización por detección temprana

### 3. RESULTADOS

Se ha aplicado la red neuronal a tres casos diferentes de funcionamiento, mostrados en la Tabla 1:

Caso	Descripción
Caso 1	Funcionamiento de los 5 equipos climatizadores. Tarado de compresores a 6 °C
Caso 2	Funcionamiento de los 5 equipos climatizadores. Tarado de compresores a 4 °C
Caso 3	Funcionamiento sin el climatizador HVH 10. Tarado de compresores a 4 °C

Tabla 1: Casos de funcionamiento

Esto se traduce en la reducción de las 4 variables de entrada inicialmente previstas a 2, ya que se particulariza la situación para tres casos diferentes, donde se fija en cada uno de ellos, el tarado de los compresores y los equipos HVH en funcionamiento, es decir, se mantienen constantes estos dos parámetros.

La Tabla 2 recoge las características y el comportamiento de la red para los 3 casos citados.

	Caso 1	Caso 2	Caso 3
Patrones usados para entrenar la red	135	33	47
Error cuadrático medio	0,11	0,01	0,04
Número neuronas en capa interna	2	2	3
Patrones usados para el test	24	5	8
Error medio relativo (%)	0,31	0,10	0,28
Coefficiente de determinación	0,91	0,90	0,94

Tabla 2: Resultados del entrenamiento y test

En primer lugar, destacan los pequeños valores del error medio relativo (todos por debajo del 0,35%). Los valores del coeficiente de determinación obtenidos también son buenos (todos por encima de 0,90) lo cual indica una buena calidad en la predicción.

La superficie de respuesta para cada caso, es diferente, notándose el efecto de la temperatura del agua de servicios

y del caudal del núcleo, especialmente a altos valores. En el caso 1 (Figura 5), el aumento se produce de manera más gradual que en el caso de funcionamiento 2 (Figura 6), donde el incremento se realiza de manera más tendida hasta valores de temperatura del agua de servicios de 21 °C, y caudal de núcleo del 94 %, a partir de los cuales, se puede observar un aumento más brusco en la temperatura de la Contención Primaria:

En el caso de funcionamiento 3 (Figura 7), el comportamiento es muy similar al otro caso de tarado de los compresores a 4°C (Figura 6), con una predicción de aumento brusco en la temperatura de la Contención Primaria para altos valores de caudal de núcleo y temperatura del agua de servicios.

Si se tiene en cuenta que el agua de servicios representa el foco frío del sistema de refrigeración, y que el compresor de cada grupo tiende a dar un valor de temperatura de fluido refrigerante próximo al que está tarado, parece evidente que




Figura 5: Predicciones de la temperatura de la Contención Primaria para el caso 1




Figura 6: Predicciones de temperatura de la Contención Primaria para el caso 2




Figura 7: Predicciones de temperatura de la Contención Primaria para el caso 3




Figura 8: Predicciones para la diferencia de temperaturas en la Contención Primaria entre los casos 1 y 2



llegará a valores más próximos de esta cifra de tarado cuando el agua de servicios esté lo más fría posible. Por tanto, la diferencia de funcionamiento entre los casos 1 y 2, se acentuará para valores de temperatura del agua de servicios bajos, y viceversa (Figura 8), tendiendo a disminuir para valores altos, es decir, que las diferencias de temperatura en la Contención serán menores para valores altos de temperatura del agua de servicios.

Por otra parte, de la misma figura se puede observar como la diferencia de nivel térmico en la Contención Primaria para un valor de temperatura fijo del agua de servicios, es mayor para altos valores de caudal del núcleo, o lo que es lo mismo, para altas cargas térmicas de las bombas que impulsan el caudal al núcleo.

#### 4. CONCLUSIONES

Las redes neuronales desarrolladas permiten aproximar con un alto grado de exactitud la temperatura que se alcanzará en la Contención Primaria, en función de la temperatura del agua del río (foco frío del sistema de refrigeración) y del caudal del núcleo, considerando el tarado de los compresores y el número de los equipos climatizadores (HVH) en funcionamiento como constantes externas en cada caso analizado. Por lo tanto, estas RNA pueden considerarse como una buena herramienta que permite la modelización del sistema en función de los parámetros citados y con la que se puede predecir, con alta fiabilidad, la respuesta del sistema ante diferentes situaciones operativas, permitiendo tomar las decisiones operacionales más adecuadas para maximizar tanto la producción energética de la central como su seguridad.

Se proporcionan 3 mapas de comportamiento, correspondientes a distintos casos de número de equipos climatizadores en funcionamiento y tarado de los compresores, que muestran la respuesta del sistema ante variaciones en la temperatura del agua del río y del caudal del núcleo, y que son de aplicación para la Central Nuclear de Sta. María de Garoña, pero se trata de un método que podría aplicarse a otras centrales nucleares, adaptándolo evidentemente a los datos históricos de cada una.

Los modelos obtenidos permiten hacer una predicción de alta precisión con mucha antelación ante situaciones de funcionamiento comunes y es compatible con las condiciones de funcionamiento seguro ya existentes que seguirían actuando en situaciones fuera del rango para el que están entrenadas las RNA. Esta antelación que permiten las RNA, encaja muy bien con la velocidad de respuesta de las centrales nucleares, en las que no es posible variar bruscamente la potencia de manera instantánea, lo que permitiría hacer trabajar a la central cerca de su óptimo durante más tiempo y con más seguridad.

Según los resultados obtenidos, en función de la indisponibilidad del equipo HVH 10, la red prevé alcanzar temperaturas por encima de los 55 °C, para temperaturas del agua de servicios superiores a 21 °C, y valores de caudal del

núcleo próximos 100 %.

Dentro de los rangos de trabajo estudiados, no se prevé alcanzar en este caso la temperatura límite en operación normal, aunque no se podría descartar alcanzarla para secuencias de operación que impliquen valores de caudal superiores.

Para las otras situaciones operativas expuestas (casos 1 y 2), no se prevé alcanzar la temperatura límite en operación normal, ya que se han presentado predicciones que distan bastante de ese valor, incluso para rangos de trabajo de temperaturas del agua de servicio y caudal del núcleo altos.

Para un funcionamiento con los 5 equipos climatizadores disponibles, se recomienda bajar el tarado de los compresores de los grupos frigoríficos de 6 a 4 °C, para los casos donde el caudal del núcleo sea superior al 93 %, y se requiera disminuir la temperatura en la Contención.

No obstante, si la temperatura del agua de servicios fuera muy elevada, podría no provocar mucho efecto el cambio de tarado en la temperatura de la Contención.

#### 5. AGRADECIMIENTOS

Se agradece a Nuclenor, S.A. la concesión de una beca para realizar prácticas en sus instalaciones de Santa María de Garoña (Burgos), lo que permitió el desarrollo de este trabajo.

#### 6. BIBLIOGRAFÍA

- Glasstone S, Sesonske A. *Ingeniería de reactores nucleares*. Carreira M (trad). Barcelona: Editorial Reverté S.A., 1990. 908p. ISBN: 84-291-4035-2.
- Nuclenor. Estudio de Seguridad. Revisión 37. 2010.
- Nuclenor. Especificaciones Técnicas de Funcionamiento de la Central Nuclear de Sta. M<sup>a</sup> de Garoña. 1986.
- Eubank RL. *Nonparametric Regression and Spline Smoothing*. 2ª edición. New York: Marcel Dekker, 1999. 360p. ISBN 0-8247-9337-4.
- Lewis FL. "Neural network control of robots manipulators". *IEEE Expert*. 2002. Vol.11-3 p.64-75.
- Bendaña-Jácome R, del Caño-Gochi A, de la Cruz-López P et Al. "Selección multicriterio de contratistas de obras. Enfoque basado en redes neuronales". *DYNA Ingeniería e Industria*. 2010 Vol.85-1 p.71-84.
- Zhang Z, Friedrich K, Velten K. "Prediction on tribological properties of short fibre composites using artificial neural networks". *Wear*. 2002. Vol.252-7 p.668-675.
- Isasi-Viñuela P, Galván-León I. *Redes de Neuronas Artificiales. Un Enfoque Práctico*. Madrid: Pearson - Prentice Hall, 2004. 248p. ISBN: 978-84-205-4025-2.
- Lippman RP. "An introduction to computing with Neural Networks". *IEEE ASSP Magazine*. 1987. Vol.3-4 p.4-22.
- Freeman A, Skapura DM. *Redes neuronales. Algoritmos, aplicaciones y técnicas de programación*. García-Bermejo R (trad). Madrid: Addison-Wesley Iberoamericana, 1993. 431p. ISBN: 0-201-60115-X.
- Zeidenberg M. *Neural networks in artificial intelligence*. 2ª edición. New York: Ellis Horwood Limited, 1990. 268p. ISBN: 0-13-612185-3.
- Hiler-González JR, Martínez-Hernando VJ. *Redes neuronales artificiales. Fundamentos, modelos y aplicaciones*. Madrid: RA-MA Editorial, 1995. 390p. ISBN: 84-7897-155-6.
- Hagan MT, Menhaj M. "Training feedforward networks with the Marquardt algorithm," *IEEE Transactions on Neural Networks*. 1994. Vol.5-6 p.989-993.
- Nuclenor. Prueba de Vigilancia. Determinación de la temperatura de la atmósfera de la Contención Primaria. 1986.
- *Should I normalize/standardize/rescale the data?* [en línea]. Warren Sarle. Febrero 2011 [Marzo 2011]. Disponible en internet: <http://www.faqs.org/faqs/ai-faq/neural-nets/part2/section-16.html>.
- Zhu J, Shi Y, Feng X et al. "Prediction on tribological properties of carbon fiber and TiO<sub>2</sub> synergistic reinforced polytetrafluoroethylene composites with artificial neural networks". *Materials and Design*, 2009. Vol.30-4 p.1042-1049.