

INGENIERÍA E INNOVACIÓN

USO DE INTELIGENCIA ARTIFICIAL (REDES NEURONALES) PARA LA OPTIMIZACIÓN DEL FUNCIONAMIENTO DE UN SISTEMA DE ENFRIAMIENTO DE AGUA NO ESENCIAL



CARLOS J. GAVILÁN MORENO
ENGINEERING DEPARTMENT MANAGER
IBERDROLA GENERACIÓN NUCLEAR
CENTRAL NUCLEAR DE COFREENTES

En muchas ocasiones, el cambio de equipos, modificaciones de diseño, o simplemente un cambio en la operación llevan a equis sistemas o componentes a trabajar en condiciones poco eficientes y no óptimas. En la actualidad recuperar la eficiencia o punto óptimo de funcionamiento de equipos, sistemas o componentes, requiere de modelos muy complejos o pruebas para determinarlos. En el primer caso, los modelos tienden a ser muy complejos, costosos y con ciertas incertidumbres. En el segundo caso, la necesidad de variar la operación, o modificaciones de variables no es bien recibido en el mundo nuclear, máxime cuando a veces se trata de explorar situaciones que están fuera de los escenarios analizados.

En estos escenarios, o con estas necesidades la inteligencia artificial, tiene una gran utilidad. Debido a que los sistemas de redes neuronales, aprende de las situaciones actuales y normales y es capaz de extrapolar a situaciones no evaluadas previamente en el diseño de la planta, no es necesario hacer pruebas e incrementar riesgos.

El trabajo actual es el uso de estas técnicas para la mejora de rendimiento de las torres de tiro mecánico, mediante el análisis de estrategias de funcionamiento de los ventiladores, caudal de aire de entrada, etc... de forma que el parámetro de optimización es la minimización de la temperatura de salida y como consecuencia de la temperatura de las salas o cubículos de la planta.

INTRODUCCIÓN

Muchos de los sistemas de las actuales centrales nucleares españolas, tienen un diseño analógico y con un fuerte componente de intervención del operador. Estos sistemas están diseñados para unas estrategias fundamentalmente reactivas, careciendo por tanto de capacidades predictivas o adaptativas. En estos sistemas analógicos la anticipación solo depende de la visión o capacidad del operador, el cual está focalizado en varios sistemas simultáneamente y en reaccionar de forma óptima y adecuada a los requerimientos de la planta.

Esta característica de los sistemas analógicos sumado a que algunas plantas han sufrido aumentos de potencia y, en el caso de sistemas de refrigeración, a cambios en las condiciones ambientales, hacen que los sistemas estén funcionando en puntos distintos del sistema original y, por su puesto, requieren una mejor adaptación y predicción de sus respuestas.

En este sentido, disponer de modelos para predecir el funcionamiento y generar la información para la adaptación a un cambio de condiciones, operativas, climatológicas o de potencia es muy útil. Los modelos, como casi todas las cosas, pueden ser de una gran complejidad para establecer una gran precisión, lo que supone un alto coste, o pueden ser modelos sencillos para establecer tendencias y bajas precisiones. Estos últimos suelen ser de poca fiabilidad y en el entorno nuclear no tienen un gran campo de aplicación. No obstante, existen modelos que aúnan los dos anteriores; son modelos de una gran sencillez pero que llegan a dar respuestas y resultados muy fiables. Los modelos a los que nos referimos son los modelos de inteligencia artificial, soportados por *big data*. Concretamente, son los modelos de inteligencia artificial, basados en redes neuronales de aprendizaje supervisado y de tipo *feedforward*.

Estos modelos de redes neuronales artificiales (RNA), tienen la gran ventaja de aprender del sistema a modelar, por el que la parametrización del modelo concreto llega a ser




Figura 1. Esquema del Sistema de Agua No Esencial Enfriada P41.




Figura 3. Correlación entre la temperatura ambiente y de agua enfriada.




Figura 2. Evolución de la temperatura ambiente (izq) y de agua enfriada (drch).

muy buena. Por este motivo los resultados son fiables y muy próximos a la realidad. Los modelos RNA tienen una arquitectura muy sencilla, parametrizable y de bajo coste de computación, mantenimiento y operación.

ANTECEDENTES

El sistema monitorizado y objeto de este modelo es el sistema de agua enfriada no esencial de la central nuclear de Cofrentes (P41).

Como se puede observar en la Figura 1 este sistema dispone como sumidero de calor de unas torres de refrigeración de tiro forzado. Así pues, las torres disponen de tres ventiladores de velocidad variable. La velocidad de los ventiladores es controlada por el operador de sala de control en función de la temperatura ambiente y la temperatura del agua de salida de torre en cada momento (acción reactiva).

El sistema está diseñado para que la temperatura del agua refrigerada por las torres de enfriamiento no supere los 32,7 °C. Así mismo el sistema tiene limitada la temperatura del agua refrigerada por las torres de enfriamiento para que no descienda de los 17 °C. El comportamiento típico, actual del sistema es reproducir la temperatura ambiente de forma lineal.

Así pues, el modelo desarrollado busca dos tipos de optimización en el funcionamiento del sistema. Por un lado, reducir la temperatura de salida del agua enfriada por la to-

rre de refrigeración y, por otro lado, reducir la diferencia entre el máximo y el mínimo, tanto diariamente como estacionalmente (Figura 2).

Este comportamiento deseado se realiza ya que si la temperatura de agua enfriada es superior a 24 °C los tres ventiladores se ponen en marcha con el consiguiente aumento de consumo energético. Esto se produce con temperatura ambiente superior a 25 °C (Figura 3).

Además, con temperaturas ambiente superiores a 30 °C se entra en el POGA. Y la temperatura del agua enfriada es tal que en un primer escalón se transfieren cargas entre el sistema de agua enfriado esencial y no esencial (P40-P41), y en el sistema de enfriamiento de agua de piscina se cambia el sumidero térmico entre P42 y P40.

MODELO Y RESULTADOS

Un primer modelo predictivo se construye para establecer la estrategia en la gestión de la velocidad y la cantidad de ventiladores en funcionamiento y que generan el intercambio y el enfriamiento del agua de servicio no esencial. Este modelo indicaría, teniendo en cuenta las variables de la Tabla 1, la velocidad media de los ventiladores (V_{med}) para una temperatura de agua refrigerada a la salida de la torre.

Con este modelo (Figura 4), la estrategia es, usando la predicción meteorológica (Figura 5) y con un valor de tempe-

Variable de entrada	Unidades
Potencia térmica de la planta	MW _{th}
Potencia eléctrica activa	MW _a
Potencia eléctrica reactiva	MVAr
Temperatura ambiente	°C
Humedad ambiente	%
Temperatura de salida de la torre (modificable)	°C

Tabla 1. Conjunto de variables de entrada a la primera red neuronal.




Figura 4. Esquema de red neuronal.

ratura de agua enfriada determinado, predecir cuáles tienen que ser las velocidades de los ventiladores.

Con este modelo se detectan algunas inconsistencias, esperables, por la sencillez del mismo. La primera es que con *setpoints* de agua enfriada bajos o fuera del mapa de entrenamiento, la velocidad media sale mayor que la máxima de los motores, es decir $V_{med} > 1500$ rpm. Otra de las inconsistencias detectada, responde a la estrategia de operación, más que a inexactitudes del modelo. Existen valores de temperaturas ambientes medias-bajas, en los que la temperatura de agua enfriada real de la torre es superior a los del *setpoint* seleccionado con la misma V_{med} . Esto responde a que en CN Cofrentes la estrategia de gestión de los ventiladores, donde no se tienen todos en marcha penaliza sobre el modelo. De aquí se deduce una primera idea, y es que tener todos los ventiladores en marcha a bajas vueltas es más eficiente que tener 1 o 2 a altas vueltas, ya que le intercambio térmico es mucho mayor. Luego la optimización del sistema es una de las primeras ventajas del modelo expuesto.

Debido a la imprecisión anterior, se decide completar el modelo concatenando 2 redes neuronales como se muestra en la Figura 6.

Este modelo bineuronal, con muchas conexiones comunes a ambas redes neuronales, ya funciona como el módulo con características de optimización y predicción. En la primera red neuronal, además de las entradas meteorológicas y de operación (potencias), se establece el *setpoint* de temperatura de salida de la torre y devuelve el valor de velocidad media de los tres ventiladores. Con este valor medio se establecen las velocidades de cada uno de los ventiladores y junto con las variables meteorológica y de operación, se simula la salida real de la torre. En esta última red neuronal está implícita la eficiencia de la torre en su conjunto, de las celdas y de los ventiladores.

La parte de simulación y optimización viene dada porque




Figura 5. Datos de partida meteorológicos (ejemplo).




Figura 6. Modelo bineuronal.

realmente las velocidades de los ventiladores no tienen que ser obligatoriamente iguales, es decir conservándose la media y con la restricción de la velocidad máxima, la velocidad puede ser distinta en cada uno. Es más, en algunos casos puede ser que un ventilador esté fuera de servicio por lo que una velocidad o dos pueden ser cero, y el otro ventilador tiene que suplir el caudal de aire. En estos casos se puede simular cuál es el valor esperado de la torre.

Resultados

Una vez definida la arquitectura del módulo de inteligencia artificial, se pasa al entrenamiento y validación de los resultados del entrenamiento. Para el entrenamiento se han tomado datos de funcionamiento de las torres de tiro forzado del sistema de agua enfriada no esencial de varios ciclos y en varias épocas del año. Un ejemplo de esas medidas son las Figuras 2 y 3.

Una vez entrenada la red y dando por supuesto que ha aprendido el funcionamiento del sistema, se procede al uso "en producción" del modelo creado. Los resultados han sido muchos y variados, pero hay dos que tienen mucho valor desde el punto de vista operativo.

Una de las pruebas llevada a cabo es la de establecer en un determinado periodo, previamente registrado, un *setpoint* de temperatura de salida fijo y de un valor de 19 °C. y simular la salida. Se observa que existe una diferencia sustancial




Figura 7. Comparación Salida modelo-Registro real.

sobre los valores registrados en la realidad ya que, sobre todo en periodos de primavera y otoño, el rendimiento de la torre mejora por la mejor gestión de los ventiladores y optimización del intercambio aire-agua. Esto hace que se reduzca el periodo donde la capacidad de la torre está saturada, ya que el inicio del verano comienza con una situación de la planta más fría. Se demuestra que, con esta gestión no se mejora la temperatura máxima de agua enfriada ni la mínima, es decir no se modifican los valores extremos, pero si los intermedios y se logra así hacer más eficiente el sumidero térmico en las situaciones de temperaturas suaves.

Segundo resultado, fruto de la segunda batería de ensayos, es la determinación del impacto de la configuración de los ventiladores para una misma velocidad media, en la temperatura de salida de agua enfriada.

Para ello se establece una temperatura objetivo de agua enfriada de 19 °C. Se determina una velocidad media de ventiladores de 800 rpm. Y con las mismas condiciones de potencias, temperatura ambiente y humedad, se simulan dos estrategias de ventiladores. La primera estrategia es con los tres ventiladores en marcha y con la velocidad igual a la velocidad media, y la segunda estrategia con un ventilador parado y los otros dos en marcha a una velocidad de giro tal que se siga manteniendo la velocidad media. Los resultados son los que se muestran en la Tabla 2, y significan que la estrategia de tres ventiladores en marcha mejora en 1 °C la temperatura de agua enfriada.

Velocidad media	Velocidad Vent. 1	Velocidad Vent. 2	Velocidad Vent 3	Temp. de agua enfriada.
850	1275	0	1275	20.204
850	930	750	870	19.605
850	900	750	900	19.222
850	850	850	850	19.000

Tabla 2. Temperatura de agua enfriada con distintas estrategias de ventiladores.

CONCLUSIONES

Con el modelo aquí desarrollado, se han cumplido dos objetivos importantes. El primero es el desarrollo de una herramienta de simulación y predicción de bajo coste y alta fiabilidad por su tasa de aciertos. Así mismo, y este es el segundo objetivo, se dota de una herramienta para optimi-

zar la gestión en el uso de los ventiladores en la torre de tiro natural.

Una de las principales conclusiones es que con esta herramienta se puede monitorizar el sistema, de forma que se puede ver si hay degradación en los internos, ya que la deriva consistente entre los valores reales y los generados, o incluso el aumento de la velocidad media de los ventiladores para una misma temperatura ambiente, puede considerarse como un indicador.

Así mismo el sistema desarrollado permite conocer de antemano las capacidades de enfriamiento de la torre en cada momento; esto es muy útil para planificar la puesta fuera de servicio de ventiladores, de predecir la temperatura de salida de torre ante una ola de calor, y programas deslastre de cargas.

Un caso importante es determinar el margen térmico de la torre en situaciones de bajas cargas térmicas de generación o del generador eléctrico, de forma que se puede programar, poner fuera de servicio, intercambiadores etc.

Como conclusión final, repetir que los modelos de inteligencia artificial son muy útiles como sistemas de apoyo a la operación y que, en casos como el presentado, ayuda al operador a gestionar de forma óptima el sistema. Una gestión óptima del sistema lleva a reducir la temperatura de agua de salida de la torre o, en otros casos, el rango de variación de temperatura entre día o la noche o entre las estaciones.

REFERENCIAS

- Yiftah, S., (1988). Neural Networks - Potential application in the nuclear industry: Preliminary comments and reflections. "Use of Expert Systems in Nuclear Safety", International Atomic Energy Agency, IAEA-TECDOC-542, pp. 177-182.
- Boger, Z., (1988). Expert systems in nuclear power plants - how soon can they be implemented? "Use of Expert Systems in Nuclear Safety", International Atomic Energy Agency, IAEA-TECDOC-542, pp. 165-176.
- Boger, Z., (1989). Survey of INIS database concerning expert systems in nuclear power plants. "Use of Expert Systems in Nuclear Safety", International Atomic Energy Agency, IAEA-TECDOC-542, pp. 97-98, 245-344.
- Boger, Z., (1991). Possible roles of neural networks in developing expert systems in the nuclear industry. "Expert Systems in the Nuclear Industry", International Atomic Energy Agency, IAEA-TECDOC-660, pp. 147-161.
- Boger, Z., (1992). The role of neural networks in nuclear power plant safety systems. "The Potential of Knowledge Based Systems in Nuclear Installations", International Atomic Energy Agency, IAEA-TECDOC-700, pp. 63-75. Also as Israeli Atomic Energy Commission technical report NRCN (TN) - 145, Dec. 1993.
- Boger, Z., (1993). The status of artificial neural networks applications in the nuclear industry. "Current Practices and Future Trends in Expert System Developments in Use in the Nuclear Industry". International Atomic Energy Agency, IAEA-TECDOC-769, pp. 33-46.

- Keter, A. and Boger, Z., (1994). Application of artificial neural networks in estimation of probable accident causes in nuclear power plants. "Current practices and future trends in expert system developments in use in the nuclear industry." International Atomic Energy Agency, IAEA-TECDOC-769, pp. 103-112.
- Stritar, A. and Laskover, M., (1994). Application of neural networks in nuclear safety analysis. "Current practices and future trends in expert system developments in use in the nuclear industry." International Atomic Energy Agency, IAEA-TECDOC-769, International Atomic Energy Agency, pp. 47-54.
- Elias, E., Wacholder, M. and Tramer, M., (1994). Nuclear power plant diagnostics using artificial neural networks. "Current practices and future trends in expert system developments in use in the nuclear industry." IAEA-TECDOC-769, International Atomic Energy Agency, pp. 137-144.
- International Working Group on NPP Control and Instrumentation (1997). Conclusions and Recommendations. "Advanced Control Systems to Improve Nuclear Power Plant Reliability and Efficiency", International Atomic Energy Agency, IAEA-TECDOC-952, pp. 98-99.
- Turkcan, E. and Ciftcioglu, O., (1993). Enhancement of verification and validation for nuclear reactors through artificial intelligence. "Operator support systems in nuclear power reactors", International Atomic Energy Agency, IAEA-TECDOC-762, pp. 271-279.
- Turkcan, E. and Ciftcioglu, O., (1993). On-line operator support system integrated with monitoring and diagnostic system. "Operator support systems in nuclear power reactors", International Atomic Energy Agency, IAEA-TECDOC-762, pp. 61-70.
- Kortesis, S y Panagiotopoulos, P.D. (1993) "Neural Network for computing in structural analysis: Methods and Prospects of applications" International Journal for numerical Methods in Engineering, Vol 36, 2305-2318.
- Dissanayake, M.W.M y Phan-thien, N. (1994) "Neural Network-Based Approximations for solving partial differential equations" Communications in numerical methods in engineering, Vol 10, 195-201.
- Hornik, K.; Stinchcombe, M.; White, H. (1989) "Multilayer feedforward networks are universal approximators" Neural Networks. Vol 2. Pp 359-366.
- C. J. Gavilán, Uso de las redes neuronales artificiales en el método de los elementos finitos. Aplicación a los problemas de transferencia de calor. Tesis Doctoral, (2003).
- Cheon, S.W; Chang, S.H; Chung, H, Y; Bien, N, Z. (1993) "Application of neural network to multiple alarm processing and diagnosis in nuclear power plants" IEEE Transactions on nuclear Science, Vol 40, No1, pp 11-20.
- Nabeshima, K; Suzudo, T; Suzuki, K; Türkcan, E. (1998) "Real-Time Nuclear Power Plant Monitoring with Neural Network" Journal of nuclear Science and Technology, Vol 35 No2, pp 93-100.
- Gavilán Moreno, C.J. (2015) "Using Neural Networks for Simulating and predicting Core-End Temperatures in Electrical Generator: Power Uprate Applications" World Journal of Engineering and Technology. 2015 Vol 3, pp 1-14.
- Gavilán Moreno, C.J. (2003) "Modelización de la fabricación de ácido fosfórico de 30% en P₂O₅, mediante redes neuronales artificiales" Rev. Industria Química, Num 404, pp 122-128.
- Gavilán Moreno, C.J. (2004) "Redes Neuronales Artificiales para la simulación de la Granulometría: Aplicación a procesos industriales de granulación" Rev. Ingeniería Química. Num 415, pp 138-147. ■